

Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

**Solução Computacional para Prevenir Acidentes
Aeronáuticos causados por Esteiras de Turbulência
usando Aprendizado de Máquina**

Daniel Valério Leite

Monografia apresentada como requisito parcial
para conclusão do Curso de Computação — Licenciatura

Orientador
Prof. Dr. Li Weigang

Brasília
2019

Universidade de Brasília
Instituto de Ciências Exatas
Departamento de Ciência da Computação

Departamento de Ciência da Computação

Solução Computacional para Prevenir Acidentes Aeronáuticos causados por Esteiras de Turbulência usando Aprendizado de Máquina

Daniel Valério Leite

Monografia apresentada como requisito parcial
para conclusão do Curso de Computação — Licenciatura

Prof. Dr. Li Weigang (Orientador)
CIC/UnB

Profa. Dra. Roberta Barbosa de Oliveira Prof. Dr. Geraldo Pereira Rocha Filho
CIC/UnB CIC/UnB

Prof. Dr. Wilson Henrique Veneziano
Coordenador do Curso de Computação — Licenciatura

Brasília, 11 de Dezembro de 2019

Dedicatória

Dedico este trabalho a minha mãe e irmãos, que sempre me estimularam a continuar nos estudos com dedicação.

Agradecimentos

Agradeço a minha mãe e família pelo empenho que foi me dado ao longo desses anos de estudos.

Agradeço ao meu Orientador, *Prof. Dr. Li Weigang* por todas as orientações e por ter confiado na minha capacidade de concluir este importante trabalho. Agradeço a todos os meus professores que estiveram nessa jornada me passando conhecimentos.

Agradeço aos meus colegas de trabalho do Cindacta I na Aeronáutica pelo apoio prestado nesses anos.

Agradeço ainda à Profa. Dra. Roberta Barbosa de Oliveira por ter me dado conselhos relevantes sobre a minha pesquisa e me guiado em pontos para melhorar o trabalho. Agradeço ao Prof. Dr. Geraldo Pereira Rocha Filho pelas orientações iniciais que alavancaram o meu trabalho.

Resumo

Esteiras de turbulência são fluxos de ar gerados e que giram a partir das pontas das asas de um avião e que permanecem por minutos no ar. Um problema fatal para muitas aeronaves é a esteira de turbulência reconhecida pela primeira vez como de extremo perigo em 1960. Diversos acidentes e incidentes ocorreram e ocorrem no mundo devido a aeronaves adentrarem a esteira de turbulência de uma aeronave maior. As aeronaves têm a capacidade de enxergar as outras ao seu redor graças a um equipamento chamado Vigilância Dependente Automática por Radiodifusão (*Automatic Dependent Surveillance-Broadcast* ADS-B) que se comunica com o ADS-B de outras aeronaves e tanto recebe quanto transmite sua posição, velocidade, altitude, identificação, entre outros. Com o uso de critérios de separação segura para esteira de turbulência de aeronaves e utilizando técnicas de Aprendizado de Máquina será possível agregar ao sistema ADS-B alertas precisos ao piloto. Com tais alertas será possível avisar do perigo de se aproximar de um vórtice gerado por uma aeronave categoria super, por exemplo, Airbus A380. A metodologia por meio de Aprendizado de Máquina será classificar qual aeronave está voando ao seu redor e a partir dessa informação de imediato saber qual a sua respectiva esteira de turbulência. A solução para o problema é justamente usar o ADS-B para detectar uma aeronave a quilômetros de distância em sua trajetória e alertar o piloto por meio sonoro e visual, pois o ADS-B atualmente não realiza tal solução proposta. Testes com diferentes algoritmos em diversos cenários de teste mostram que os melhores resultados para uma separação mínima em voo e um tempo seguro para iniciar a decolagem é obtido com a utilização tanto do algoritmo *Naive Bayes* como do *KNN* com parâmetro $k = 1$ ou 3 . Tais informações são suficientes para o piloto manter as devidas separações para com a outra aeronave e assim evitar um acidente aeronáutico, pois é sabido que esteiras de turbulência de aviões categoria pesada e super são de extremo perigo. Sendo assim, o piloto em caso de não ser avisado do perigo pelo Controlador de Tráfego Aéreo por qualquer motivo que seja, poderá ter sua própria tomada de decisão dentro da sua cabine para evitar um vórtice de uma aeronave maior.

Palavras-chave: Esteira de Turbulência, Aeronave, Algoritmo, ADS-B, Aprendizado de Máquina.

Abstract

Wake turbulence are generated air streams that rotate from the wingtips of an airplane and remain for minutes in the air. A fatal problem for many aircraft is the turbulence wake first recognized as extremely dangerous in 1960. Several accidents and incidents have occurred and occur worldwide as aircraft enter the turbulence wake of a larger aircraft. Aircraft have the ability to see others around them thanks to equipment called Automatic Dependent Broadcast Surveillance that communicates with ADS-B from other aircraft and receives and transmits their position, speed, altitude, identification, among others. Using safe separation criteria for aircraft turbulence and using Machine Learning techniques, it will be possible to add to the ADS-B system accurate pilot alerts. With such warnings it will be possible to warn of the danger of approaching a vortex generated by a super category aircraft, for example Airbus A380. The Machine Learning methodology will be to classify which aircraft is flying around you and from this information immediately know your turbulence wake. The solution to the problem is precisely to use ADS-B to detect an aircraft miles away in its trajectory and alert the pilot by sound and visual, as ADS-B currently does not perform such a proposed solution. Tests with different algorithms in several test scenarios show that the best results for minimum flight separation and a safe takeoff time are obtained using either the Naive Bayes algorithm or the KNN with parameter $k = 1$ or 3 . Such information is sufficient for the pilot to maintain proper separation from the other aircraft and thus to avoid an aeronautical accident, as it is known that turbulence mats of heavy and super category aircraft are of extreme danger. Therefore, if the pilot is not warned of the danger by the Air Traffic Controller for any reason, he may have his own decision in his cabin to avoid a vortex of a larger aircraft.

Keywords: Wake Turbulence, Aircraft, Algorithm, ADS-B, Machine Learning.

Sumário

1	Introdução	1
1.1	Contextualização	1
1.2	Definição do Problema	2
1.3	Objetivo Geral	5
1.4	Objetivos Específicos	6
1.5	Metodologia	6
1.6	Estrutura do Trabalho	7
2	Trabalhos Relacionados e Criação de uma Solução	8
2.1	Sistema para Processamento de Esteiras de Turbulência	8
2.2	Outras Abordagens	9
2.3	Solução criada usando Aprendizado de Máquina	16
2.4	Evolução do Sistema de Vigilância de Tráfego Aéreo (ADS-B)	19
2.4.1	Generalidades do ADS-B	20
2.5	<i>Compact Position Reporting</i> (CPR)	24
2.6	Considerações Finais	25
3	Fundamentação Teórica	27
3.1	Aprendizado de Máquina	27
3.1.1	Aprendizado Supervisionado - Classificação	27
3.2	<i>Naive Bayes</i>	29
3.2.1	Aplicações do Algoritmo	30
3.2.2	Equação Matemática	31
3.3	Rede Neural Perceptron Multicamadas	32
3.4	Árvore de decisão C4.5	35
3.4.1	Equação Matemática	36
3.5	Vizinhos mais Próximos	37
3.5.1	Distância Euclidiana	38

3.6	Pré-Processamento dos Dados	40
3.6.1	Valores incorretos	40
3.6.2	Amostragem	41
3.6.3	Classificação	41
3.7	Ambiente de Testes <i>Weka</i>	43
4	Modelagem e Aplicação	44
4.1	Solução Proposta	44
4.1.1	Generalidades	44
4.2	Fonte de Dados: EUROCONTROL RECAT-EU (<i>European Wake Turbulence Categorisation and Separation Minima on Approach and Departure</i>) .	47
4.2.1	Categorias de Esteiras de Turbulência	48
4.2.2	Categoria Pesada	49
4.2.3	Categoria Média	50
4.2.4	Novas Categorias de Aeronaves	54
4.2.5	Mínimos de separação com base na distância no momento do pouso e da decolagem	56
4.2.6	Mínimos de separação com base no tempo - decolagem	56
4.3	Vantagens do ADS-B em relação as Categorias de Esteiras de Turbulência .	57
4.4	Fluxogramas das Soluções	58
4.5	ADS-B Atual e ADS-B depois da Solução Proposta	61
4.5.1	ADS-B Atual	61
4.5.2	ADS-B com a Solução Proposta	61
5	Simulações e Resultados	65
5.1	Configuração dos Cenários de Teste	65
5.1.1	Seleção de Algoritmos	65
5.1.2	Seleção de Parâmetros - Algoritmos de Classificação	66
5.2	Experimentos	66
5.2.1	Cenário 1: Tempo para Decolagem Segura	66
5.2.2	Cenário 2: Distância Baseada na Separação Mínima em Voo	67
5.3	Metodologia - Resultados	69
5.4	Avaliação do Resultado dos Cenários	69
5.4.1	Naive Bayes	70
5.4.2	Perceptron Multicamadas	70
5.4.3	Árvore de Decisão <i>C4.5</i>	71
5.4.4	K - Vizinhos mais Próximos	71
5.4.5	Análise dos Resultados dos Algoritmos	73

5.4.6 Resultados	74
6 Conclusões e Trabalhos Futuros	75
6.1 Contribuições e Pesquisas Futuras	75
6.2 Considerações Finais	77
Referências	78
Apêndice	84
A Acidentes Aeronáuticos Envolvendo Esteiras de Turbulência	85
Anexo	97
I Definições de Termos Aeronáuticos	98
II Comparação dos mínimos de separação entre a ICAO e a RECAT-EU	104

Lista de Figuras

1.1	Vórtice gerado pela asa de um avião [54].	3
1.2	Vórtice gerado pela asa de um avião [54].	3
1.3	Jato em queda livre após cruzar esteira de turbulência de Airbus A380 [3].	4
1.4	Situação no interior do jato após entrar na esteira de turbulência [3]. . . .	4
2.1	Esteira de turbulência de um avião. FAA AC 90-23G [7].	10
2.2	Comunicação via ADS-B de aeronaves/Satélites[18].	10
2.3	Aplicativo Flight Weather Viewer [40].	11
2.4	Dados ACARS comunicação terra-ar [15].	12
2.5	Sistema AMDAR [85].	13
2.6	Sistema LIDAR [57].	14
2.7	Radar ETURB [10].	15
2.8	Aplicativo Flight Weather Viewer [40].	16
2.9	Aeronave bem próximo da aeronave principal na tela do ADS-B [35]. . . .	17
2.10	Aeronaves se comunicando pelo ADS-B[70].	18
2.11	Antenas ADS-B [23].	22
2.12	Tráfego ADS-B exibido em um GNS com montagem em painel da Garmin [39].	22
2.13	Símbolo que representa a própria aeronave na tela do ADS-B.	23
2.14	Símbolo que representa uma aeronave não intrusa em relação a aeronave no centro da tela do ADS-B.	23
2.15	Símbolo que representa uma aeronave intrusa em relação a aeronave no centro da tela do ADS-B.	24
3.1	Técnicas de aprendizagem de máquina [17].	28
3.2	Modelo geral da Aprendizagem Supervisionada [17].	28
3.3	Técnica de <i>Naive Bayes</i> [72].	30
3.4	Equação Matemática de Naive Bayes [58].	31
3.5	Técnicas de MLP[27].	33
3.6	Exemplo de Árvore de Decisão [71].	35

3.7	Fórmula de ganho de informação de Árvore de Decisão [71].	36
3.8	Fórmula de ganho de Árvore de Decisão[71].	36
3.9	Exemplo dos passos do KNN [36].	38
3.10	Fórmula Euclidiana [36].	39
3.11	Matriz confusão[18].	43
4.1	Maiores aeronaves do mundo. Categoria J (Super Jumbo) [34].	45
4.2	Airbus A380 próximo de um Boeing 737-330[75].	46
4.3	Airbus A380 próximo de um Airbus A320 [55]	46
4.4	Su-35 com elevado ângulo de ataque [79]	47
4.5	ICAO: <i>categorias de esteiras de turbulência e separação mínima</i> [26]	48
4.6	Comparação do tamanho da aeronave entre AIRBUS A340-600 e BOEING B767-300 [26]	49
4.7	Distância conservadora da ICAO para o AIRBUS A340-600 e BOEING B767-300 [26]	50
4.8	Distância mais eficiente e segura também pelo Recat-eu para o AIRBUS A340-600 e BOEING B767-300 [26]	50
4.9	Comparação do tamanho da aeronave EMBRAER ERJ-145 e AIRBUS A320 [26].	51
4.10	Separação mínima de turbulência da OACI aplicável ao A320 e para o ERJ-145 seguindo A340-600 [26].	52
4.11	Separação de turbulência de vigília RECAT-EU mínima aplicável a A320 e para ERJ-145 seguindo A340-600 [26].	53
4.12	Exemplo de novas categorias de aeronaves [26].	54
4.13	Exemplo de lista de tipos de aeronaves atribuídos às categorias RECAT- EU) [26].	55
4.14	Mínimos de separação baseados na distância RECAT-EU WT na aproxi- mação e partida [26].	56
4.15	Mínimos de separação com base no tempo RECAT-EU WT no momento da partida [26].	57
4.16	Fluxograma após implementação da solução no momento da decolagem usando o ADS-B e técnicas de Machine Learning.	59
4.17	Fluxograma após implementação da solução no momento do pouso usando o ADS-B e técnicas de Machine Learning.	59
4.18	Fluxograma após implementação da solução estando a aeronave em voo usando o ADS-B e técnicas de Machine Learning.	60
4.19	Esteira de turbulência na decolagem e no pouso [25].	60
4.20	Tela do ADS-B exibindo o seu tráfego [21].	61

4.21	Tela do ADS-B exibindo a detecção da esteira de turbulência de um Airbus A380.	62
4.22	Tela do ADS-B exibindo a detecção da esteira de turbulência de um Airbus A380.	63
4.23	Tela do ADS-B exibindo a detecção da esteira de turbulência de um Airbus A380.	64
5.1	Aeronave decolando e gerando sua esteira de turbulência [29].	67
5.2	Esteira de turbulência de um avião em voo [47].	68
5.3	Aeronave pousando e gerando sua esteira de turbulência [28].	68
6.1	Esteira de turbulência de um avião em voo[37]	77
A.1	Ilustração da esteira de turbulência do voo da Qantas[6].	85
A.2	C130 KC-3803[69].	86
A.3	Destroços do C130 KC-3803[53].	86
A.4	Exemplo de um Embraer E170[69].	87
A.5	Exemplo de um Airbus A340[53].	87
A.6	Exemplo de um Robin DR 400[5].	88
A.7	Exemplo de um Antonov AN2[4].	88
A.8	Exemplo de um PIPER Cherokee (PA-28-140)[65].	89
A.9	Exemplo de um Sikorsky S-76 [67].	89
A.10	Exemplo de um AC-130U Spooky [74].	90
A.11	Exemplo de um Pilatus PC-12 [82].	90
A.12	Exemplo de um Airbus A319 [68].	91
A.13	Exemplo de um Boeing 744 [66].	91
A.14	Exemplo de um BOEING 767-300 [33].	92
A.15	LearJet45, XC-VMC [11].	93
A.16	Destroços da queda do Learjet 45-XC [44].	93
A.17	Exemplo de um Boeing 747 [19].	94
A.18	Exemplo de um Airbus A300-600 [62].	94
A.19	Exemplo de um Boeing 757 [63].	95
A.20	Exemplo de um IAI 1124 Westwind [64].	95
A.21	Exemplo de um North American XB-70 Valkyrie [41].	96
A.22	Exemplo de um Lockheed F-104 Starfighter [80].	96
A.23	Colisão do F-104 com o XB-70 [83].	97

Lista de Tabelas

5.1	Resultado médio das classes - Naive Bayes.	70
5.2	Matriz Confusão - Naive Bayes.	70
5.3	Resultado médio das classes - MLP.	70
5.4	Matriz Confusão - MLP.	71
5.5	Resultado médio das classes - J48.	71
5.6	Matriz Confusão - J48.	71
5.7	Resultado médio das classes - IBK.	72
5.8	Matriz Confusão - IBK.	72
5.9	Resultado médio das classes - IBK.	72
5.10	Matriz Confusão - IBK.	72
5.11	Resultado médio das classes - IBK.	72
5.12	Matriz Confusão - IBK.	73

Lista de Abreviaturas e Siglas

ACARS Aircraft Communications Addressing and Reporting System.

ADS-B Automatic Dependent Surveillance-Broadcast.

AMDAR Aircraft Meteorological Data Relay.

ANAC Agência Nacional da Aviação Civil.

APIs Application Programming Interface.

ATIS Air Travel Information Service.

CAT Clear Air Turbulence.

CDTI Cockpit Display of Traffic Information.

CPR Compact Position Reporting.

CVR Cockpit Voice Recorder.

DECEA Departamento de Controle do Espaço Aéreo.

DELICAT Demonstration of LIdar based Clear Air Turbulence detection.

E-TURB Radar Enhanced Turbulence Radar.

FAA Federal Aviation Administration.

FDR Flight Data Recorder.

FIS-B Flight Information Service-Broadcast.

GNSS Global Navigation Satellite System.

GPS Global Position System.

LIDAR Light Detection And Ranging.

NASA National Aeronautics and Space Administration.

NOTAMS Notes to Airmen.

RVSM Reduced Vertical Separation Minima.

SRR Secondary Surveillance Radar.

TAPS Turbulence Automatic PIREPS System.

TIS-B Traffic Information Service-Broadcast.

TransLab Laboratório de Modelos Computacionais para Transporte Aéreo.

WEKA Waikato Environment for Knowledge Analysis.

Capítulo 1

Introdução

O presente trabalho propõe agregar valor a um equipamento chamado Vigilância Dependente Automática por Radiodifusão (Automatic Dependent Surveillance-Broadcast ADS-B) usando Aprendizado de Máquina para alertar o piloto a manter distância e um tempo seguro para com outras aeronaves que provocam uma esteira de turbulência muito forte.

1.1 Contextualização

Ao longo das décadas acidentes aeronáuticos aconteceram e ainda acontecem devido a aeronaves ingressarem em esteiras de turbulência muito fortes [78]. Visando prevenir tais acidentes é que foi pensado em separações mínimas e um tempo seguro para decolagens. Com o uso do ADS-B é possível obter informações de altitude, velocidade e posição de outras aeronaves a várias milhas de distância [35]. Será apresentado nesse trabalho técnicas de Aprendizado de Máquina (subárea de pesquisa da Inteligência Artificial), com a finalidade de desenvolver técnicas computacionais capazes de adquirir conhecimento de forma automática. Utilizando as regras de separação segura por distância e de tempo para com as esteiras de turbulência de outras aeronaves possibilitando perfeitamente a geração de alertas audiovisuais ao piloto em sua própria cabine. A esteira de turbulência é uma ameaça real invisível no céu e que provoca desastres sempre sem avisos.

Em 12 de junho de 2016, uma aeronave *Piper Saratoga* que tem esteira de turbulência categoria leve cruzou abaixo da trajetória de um Boeing 737. A aeronave leve se despedaçou no ar devido o impacto da esteira de turbulência do Boeing 737. Os dois ocupantes da aeronave, o piloto e o passageiro morreram [9].

Atualmente o piloto consegue saber pelo ADS-B se tem outras aeronaves ao seu redor, mas o piloto não tem o conhecimento de qual categoria de esteira de turbulência de uma aeronave está se aproximando de seu avião e esse é o ponto importante do projeto

para se evitar que o avião menor entre ou cruze por uma esteira de turbulência muito forte gerada por outra aeronave bem maior. Portanto, com aplicações de Aprendizado de Máquina que será proposto nesse trabalho será possível ao piloto visualizar na tela do ADS-B se a aeronave que se aproxima é de categoria leve, médio inferior, médio superior, pesado inferior, pesado superior e super pesada. O piloto terá uma expertise para se afastar o necessário da esteira de turbulência da aeronave que se aproxima ou até mesmo da que se afasta, pois a esteira de turbulência de uma aeronave que se afasta permanece por minutos no ar. Dar essa autonomia ao piloto é importante em casos em que o Controlador de Tráfego Aéreo não possa se comunicar com o piloto para alertar sobre o perigo que se aproxima. Vale ressaltar que em alguns desses acidentes o piloto não tinha informações de quais aeronaves estavam ao seu redor. De modo que, caso o piloto tivesse estas informações, isto resultaria numa detecção de perigo e uma mudança de rota antecipada ou apenas manter uma distância segura.

Esta monografia se propõe a integrar o sistema ADS-B com informações das categorias de esteiras de turbulência das aeronaves ao seu redor com antecedência, a fim de realizar alertas ao piloto em tempo real.

1.2 Definição do Problema

As aeronaves quando se deslocam geram uma mudança muito forte na velocidade do vento atrás das suas asas, criando a chamada esteira de turbulência, que causa um perigo enorme as outras aeronaves. O ar que passa na parte inferior da asa possui uma pressão maior que o ar na parte superior da asa. Essa diferença de pressão faz com que o ar da parte inferior da asa seja forçado a fluir até as pontas da asa, gerando os vórtices. Os vórtices causam uma resistência maior no avanço, gerando assim um arrasto muito forte [54].

Os três efeitos básicos da esteira de turbulência sobre as aeronaves são: o balanço violento, a perda de altura ou de velocidade ascensional e os esforços de estrutura. O perigo maior é o balanço violento da aeronave que penetra na esteira até um ponto que exceda sua capacidade de comando para resistir a esse efeito. Se o encontro com o vórtice ocorrer na área de aproximação, seu efeito será maior pelo fato de a aeronave que seguir atrás se encontrar numa situação crítica com relação à velocidade, empuxo, altitude e tempo de reação [2].

A figura 1.1 mostra o vórtice gerado na asa e deslizando até a ponta da asa. A figura 1.2 mostra a diferença de pressão do ar na asa, ou seja, a parte de cima da asa tem um pressão menor do que a parte de baixo e isso ocasiona na geração da esteira de turbulência.




Figura 1.1: Vórtice gerado pela asa de um avião [54].



Figura 1.2: Vórtice gerado pela asa de um avião [54].

Acidente/incidente relatado em relatórios de investigação no mundo [78]:

Bombardier Challenger 604, sobre o Mar Árábico. Diversos passageiros se machucaram, um deles gravemente. A figura 1.4 mostra que a aeronave ficou muito danificada e, conseqüentemente, inservível, 2017 [3].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO *AIRBUS* A380: SUPER
CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO *BOMBARDIER CHALLENGER* 604: MÉDIA

A figura 1.3 mostra que o jato de negócios *Bombardier Challenger* 604, voando a 34.000 pés (10.370 m), que sofreu danos irreparáveis em sua estrutura e ferimentos sérios em dois passageiros a 12 mn de distância da passagem sobre eles de um *Airbus* A380, a Agência Europeia de Segurança de Voo (Easa) emitiu mais um boletim de alerta sobre o assunto, embora não houvesse por parte da tripulação das duas aeronaves qualquer desvio nas normas de segurança. A separação vertical de 1.000 pés foi mantida e, mesmo assim, o *Challenger* – apanhado de surpresa – entrou em um parafuso, perdendo altitude antes de sua recuperação com danos permanentes em sua estrutura [3]. Na aplicação da separação vertical entre um *AIRBUS* A380 e demais aeronaves, deve-se adicionar 300m (1000 pés) às regras previstas para separação vertical mínima [24].



Figura 1.3: Jato em queda livre após cruzar esteira de turbulência de Airbus A380 [3].




Figura 1.4: Situação no interior do jato após entrar na esteira de turbulência [3].

Em alguns casos o piloto não sabia que estava se aproximando de uma aeronave que gera uma esteira de turbulência capaz de causar danos em sua aeronave menor e até a morte dos tripulantes e passageiros.

As imagens das aeronaves tem o intuito de proporcionar uma compreensão sobre as aeronaves citadas no texto e qual a dimensão de fato cada uma possui em relação as outras envolvidas nos acidentes.

Não é de hoje que os perigos de voar uma aeronave de porte médio ou leve atrás de uma aeronave pesada, como o Boeing 747 ou, principalmente, o superjumbo Airbus A380, sem observar distâncias mínimas, pode ser perigoso. Os minivórtices que se formam nas pontas das asas dos grandes jatos se propagam – sem serem detectados – a quilômetros de distância, podendo causar uma turbulência violenta em aeronaves mais leves, que voam a distâncias inferiores às recomendadas pelos órgãos de regulação.

Embora, o Boeing 757 tenha o seu peso enquadrado na categoria média, às autoridades o colocam na categoria pesado devido a sua esteira de turbulência. Os Controladores de Tráfego Aéreo se encarregam de fazer uma separação segura para que um jato não venha a entrar numa esteira de turbulência de um Airbus A380, o que causaria danos sérios a um jato ou até mesmo derrubá-lo, por exemplo.

Problemas no equipamento de comunicação podem fazer com que o piloto perca a comunicação por voz e dados com os Controladores fazendo com que o piloto voe por determinado tempo às cegas. Sem falar que o ser humano está susceptível a falhas e por isso deve se buscar melhorar as tecnologias existentes para obtenção de informações confiáveis e precisas. Com o uso do Aprendizado de Máquina será possível apontar qual tipo de aeronave, ou seja, a categoria de turbulência das aeronaves para auxiliar o piloto na tomada de decisão e assim evitar um acidente aeronáutico. A solução a ser utilizada é usar o ADS-B das aeronaves para prover alertas com antecedência sobre o perigo que circunda a sua aeronave.

No Apêndice A se encontram mais casos de acidentes aeronáuticos envolvidos com as esteiras de turbulência.

1.3 Objetivo Geral

Possibilitar ao sistema ADS-B a capacidade de orientar o piloto em tempo real a tomar decisões preventivas e corretivas para que não venha a se envolver em um acidente gerado por uma esteira de turbulência. Usando Aprendizado de Máquina que tem a capacidade de classificação será possível detectar as aeronaves e distinguir automaticamente o tipo de aeronave. Após classificar qual tipo de aeronave será possível informar qual a categoria de esteira de turbulência da outra aeronave.

1.4 Objetivos Específicos

- Proposição de uma *metodologia computacional* para o problema de acidentes aeronáuticos envolvendo esteiras de turbulência. Apresentar uma solução para se evitar acidentes aeronáuticos em voo devido a esteiras de turbulência geradas por aeronaves, agregando o uso do Aprendizado de Máquina juntamente com o ADS-B a bordo das aeronaves e possibilitando mais informações que possam auxiliar os pilotos a terem tomadas de decisões próprias em caso de falhas de comunicação;
- Desenvolvimento de uma *solução*, conforme a metodologia proposta, separada em componentes: rastreamento de aeronaves e suas posições de voo, altitude, velocidade;
- Obter *resultados* seguindo a solução proposta que permita a configuração do sistema utilizando técnicas de Aprendizado de Máquina, para realizar simulações em cenários de teste, e por fim, reportar os resultados nas diferentes métricas pré-estabelecidas;
- Identificação de *resultados ótimos* para o sistema proposto com a comparação das simulações realizadas a partir dos diferentes cenários de teste.

1.5 Metodologia

O trabalho será realizado utilizando a seguinte metodologia de pesquisa:

- **Investigação sobre acidentes aeronáuticos envolvendo esteiras de turbulência:** análise dos acidentes no mundo com aeronaves;
- **Revisão bibliográfica do uso do Aprendizado de Máquina:** estudo de algoritmos de aprendizado supervisionados;
- **Levantamento de dados de categorias de esteiras de turbulência:** rastreamento de informações das aeronaves e de suas posições, altitude, velocidade de voo, entre outros. Distância segura para outra aeronave e tempo mínimo de espera para decolagem e pouso. Através de dados obtidos da Eurocontrol (Organização Europeia para a Segurança da Navegação Aérea - European Organization for the Safety of Air Navigation) é possível organizar uma base de dados. Utilizando as métricas de distância de uma aeronave para outra e do tempo de espera para uma decolagem segura será possível obter os resultados;
- **Definição da solução:** proposta para orientar o piloto através do ADS-B em sua cabine lhe provendo alertas sobre aeronaves com categorias de esteiras de turbulência muito forte ao seu redor;

- **Simulação:** realização de simulações em diferentes cenários de teste;
- **Análise de resultados:** definição de diferentes métricas para avaliar e comparar os cenários simulados e seus resultados obtidos;
- **Seleção de resultados:** identificação de resultados ótimos segundo análise dos resultados obtidos.

1.6 Estrutura do Trabalho

Este trabalho está dividido em seis capítulos. O Capítulo 2 apresenta trabalhos relacionados a problemas com esteiras de turbulências e a criação de uma solução para esteiras de turbulência usando Aprendizado de Máquina. No Capítulo 3 é apresentado a fundamentação teórica dos conceitos relevantes do Aprendizado de Máquina. No Capítulo 4 é feita uma descrição detalhada das fontes de dados utilizadas no projeto: dados relacionados as categorias de esteiras de turbulência necessários a realização dos testes. No Capítulo 5 são feitas combinações de algoritmos e em diferentes cenários de teste usando o *Weka* [1]. Neste capítulo, também são definidas as métricas utilizadas para se avaliar o desempenho dos experimentos, que por sua vez são usadas para comparar e discutir os resultados obtidos dos mesmos. Parâmetros ótimos são encontrados para cada componente da solução proposta. Por fim, no Capítulo 6 são discutidas as conclusões e resultados da pesquisa, assim como sugestões de trabalhos futuros.

Capítulo 2

Trabalhos Relacionados e Criação de uma Solução

Neste Capítulo é feita uma análise das soluções criadas ou em criação para resolver problemas de esteiras de turbulência e de turbulências no geral. Esteiras de turbulência são fenômenos gerados pela aeronave e não por um fenômeno natural atmosférico. Serão apresentadas duas abordagens para o tratamento do problema de turbulências no geral e em específico de esteiras de turbulência.

2.1 Sistema para Processamento de Esteiras de Turbulência

Kent, Kirkland e Redmond (2015) propuseram um sistema para exibir, quando uma aeronave dentro de uma trajetória de voo, um símbolo representando a turbulência de outra aeronave com base no tipo de aeronave e nos parâmetros de voo recebidos da outra aeronave, sendo o símbolo formatado para indicar a gravidade de partes do vórtice [22]. O trabalho usa o sistema ADS-B como meio de disponibilizar as informações necessárias sobre as aeronaves vizinhas.

Em outro trabalho, Le Castera e Cheung (2018) propuseram um servidor em terra configurado para identificar o encontro de aeronaves com esteiras de turbulências geradas por pelo menos outra aeronave geradora. O servidor em terra é configurado para: coletar dados aviônicos para uma aeronave em voo e dados de tráfego para uma ou mais outras aeronaves em voo no primeiro horário de voo da aeronave em voo; determinando que a aeronave a bordo estava perto de uma turbulência estimada, usando os dados de tráfego, a ser gerada por outra aeronave; determinar que a aeronave em voo sofreu um impacto severo no primeiro voo; determinar que a aeronave em voo experimentou no primeiro

horário de voo pelo menos um dentre: um ou forças e momentos não comandados, e uma assinatura de vento indicativa de turbulência na esteira; e em resposta, gerar um relatório de um encontro de turbulência de vigília para as aeronaves a bordo no primeiro voo [59].

2.2 Outras Abordagens

O conceito de turbulência pode ser descrito como um movimento ou distúrbio atmosférico que se caracteriza pela mudança da direção e da velocidade do vento, resultante das variações de pressão e temperatura que ocorrem em uma massa de ar. O conceito pode também ser aplicado quando se ocorre uma alteração na velocidade e na direção de deslocamento de uma corrente de ar por conta da presença de barreiras naturais, como montanhas, ou artificiais, como prédios. As constantes variações que afetam o escoamento das partículas de uma massa de ar e as mudanças de velocidade e direção de deslocamento de uma corrente de ar originam bruscos movimentos verticais ascendentes e descendentes atribuindo-se a essa ocorrência o conceito de turbulência.

Esteiras de Turbulência: Este distúrbio ocorre durante pousos e decolagens, quando intensos redemoinhos e vórtices, que podem chegar até 300 km/h, são produzidos na ponta das asas dos aviões, dependendo do tamanho e peso da aeronave. Manifestam-se quando o fluxo de ar que passa abaixo da asa de uma aeronave (intradorso) é conduzido para a área acima da asa de uma aeronave (extradorso), através da diferença de pressão maior no intradorso e menor no extradorso. Caso encontre esteiras de turbulência, é importante não aplicar movimentos bruscos nos ailerões, leme de direção e profundor. Essa medida visa a evitar o desgaste da estrutura da aeronave e o rompimento de cabos que conectam as superfícies de comando [46].

A esteira de turbulência não é um fenômeno natural, mas sim um vórtice gerado pela própria aeronave. Fisicamente, na figura 2.1 a esteira apresenta o comportamento inicialmente de se mover para baixo e depois manter-se nivelada. Ela nunca é encontrada no mesmo nível, nem abaixo de 300 metros que a aeronave geradora. Geralmente, os vórtices apresentam uma razão de descida de 100 a 150 metros por minuto, nos primeiros 30 segundos. A razão de descida diminui, atingindo zero entre 150 a 300 metros abaixo da linha de voo. A velocidade da aeronave irá determinar a força e o movimento inicial do vórtice. Portanto, a melhor maneira da aeronave seguidora evitar a esteira de turbulência é voando acima do nível de voo da aeronave líder [52].

As soluções existentes abordam o objetivo comum de resolver o problema de turbulências no geral, mas a solução proposta nesse projeto é em específico para esteiras de turbulências com o uso do ADS-B agregando técnicas de Aprendizado de Máquina. No trabalho proposto, são utilizados dados de separação e de tempo para decolagem de acordo




Figura 2.1: Esteira de turbulência de um avião. FAA AC 90-23G [7].

com as categorias de esteiras de turbulência. Mais especificamente, é utilizado o *Automatic Dependent Surveillance-Broadcast (ADS-B)* para rastreamento das outras aeronaves e consequentemente informar ao piloto do perigo de uma esteira de turbulência muito forte estar em sua direção. A figura 2.2 mostra o sistema ADS-B se comunicando com as outras aeronaves via satélite e antenas.



Figura 2.2: Comunicação via ADS-B de aeronaves/Satélites[18].

Algumas soluções foram criadas como:

- 1 – Sensores para captar turbulências;

2 – A *Boeing* está desenvolvendo um detector a laser que ficará no nariz do avião para captar adversidades meteorológicas;

A ideia da *Boeing* é usar uma câmera digital, equipada com uma lente para tirar fotos continuamente. Um programa de computador compara, em tempo real, cada imagem com a sua subsequente. Essa comparação poderia detectar variações de refração na linha do horizonte, causadas por mudanças na temperatura e na densidade do ar, induzidas pela zona de turbulência invisível à frente [51]. Se uma aeronave tem 70 segundos antes de entrar em turbulência, a tripulação tem tempo suficiente para acionar os avisos para apertar os cintos de segurança e suspender os serviços de cabine enquanto o avião muda seu trajeto de voo, incluindo preparar uma aterrissagem. Para uma aeronave de grande porte, os 70 segundos podem dar tempo para 80% dos passageiros a bordo estarem sentados e com os cintos fixados, de acordo com testes realizados pela NASA [56].

3 – Captação de condições meteorológicas por satélite.

Nenhum trabalho foi encontrado usando o ADS-B como solução para prover informações suficientes para que o piloto não adentre uma esteira de turbulência.

Tecnologias mais detalhadas no uso das turbulências aeronáuticas estão abaixo [46]:

- Dados CVR ("Cockpit Voice Recorder") / FDR ("Flight Data Recorder"): Dados quantitativos fornecem mais detalhadamente e de forma mais realista as forças aerodinâmicas que impactam determinada aeronave em condições de turbulência. Os parâmetros medidos são: flutuação de velocidade, aceleração vertical e rajadas derivadas.




Figura 2.3: Aplicativo Flight Weather Viewer [40].

- **Índices de Turbulência:** São equações físicas, matemáticas e termodinâmicas que retratam os mecanismos de formação da turbulência. Esses índices são introduzidos em modelos numéricos de previsão do tempo e programas de computador que fornecem informações e dados de potenciais áreas de turbulência para fins de previsão e análise.

- **Dados ACARS** (*Aircraft Communications Addressing and Reporting System*) / **AM-DAR** (*Aircraft Meteorological Data Relay*):

São dados transmitidos automaticamente para satélites e retransmitidos para centros de pesquisa, contendo diversas informações de determinado voo. Contém dados como a quantidade de passageiros a bordo, altitude, rota, condições meteorológicas etc. Os dados meteorológicos podem apresentar eventuais cenários de turbulência que determinada aeronave possa ter atravessado.

Como a aeronave é acompanhada



Figura 2.4: Dados ACARS comunicação terra-ar [15].

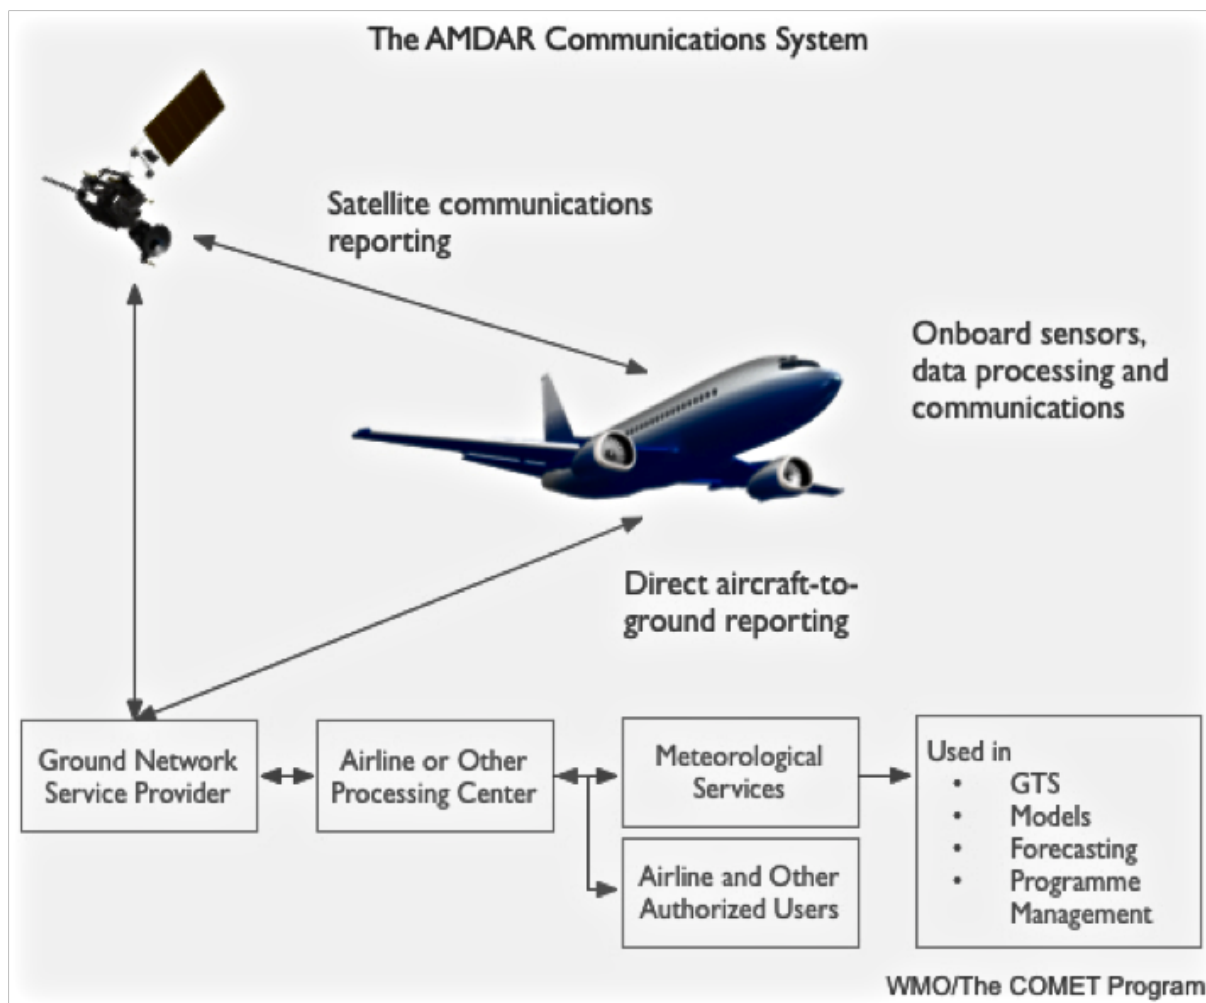


Figura 2.5: Sistema AMDAR [85].

- Algoritmos de Previsão de Turbulência:

A instalação de algoritmos de previsão de turbulência em modelos numéricos de previsão do tempo e radares meteorológicos é de grande importância no objetivo de se detectar, com maior exatidão, regiões de turbulência. Suas sequências lógicas matemáticas, físicas e computacionais trazem um maior detalhamento e precisão para as previsões e técnicas de detecção de áreas de turbulência.

- Radar LIDAR de detecção de CAT (DELICAT):

Com o avanço da tecnologia em radares, um sistema de radar que se utiliza da técnica de radiação ultravioleta a laser em ondas curtas está sendo desenvolvido pelo Centro Aeroespacial Alemão e Instituto de Ciências Atmosféricas ("German Aerospace Centre and Institute of Atmospheric Physics" – DLR), para fins de detecção de turbulências de céu claro a bordo de aeronaves. O radar se baseia no tempo de retorno da emissão do laser de volta à sua origem. Através do tempo calculado de retorno do laser, o espalhamento

das moléculas de aerossóis e as oscilações de velocidade do vento perante o sinal emitido traduzem a possibilidade da existência da turbulência.

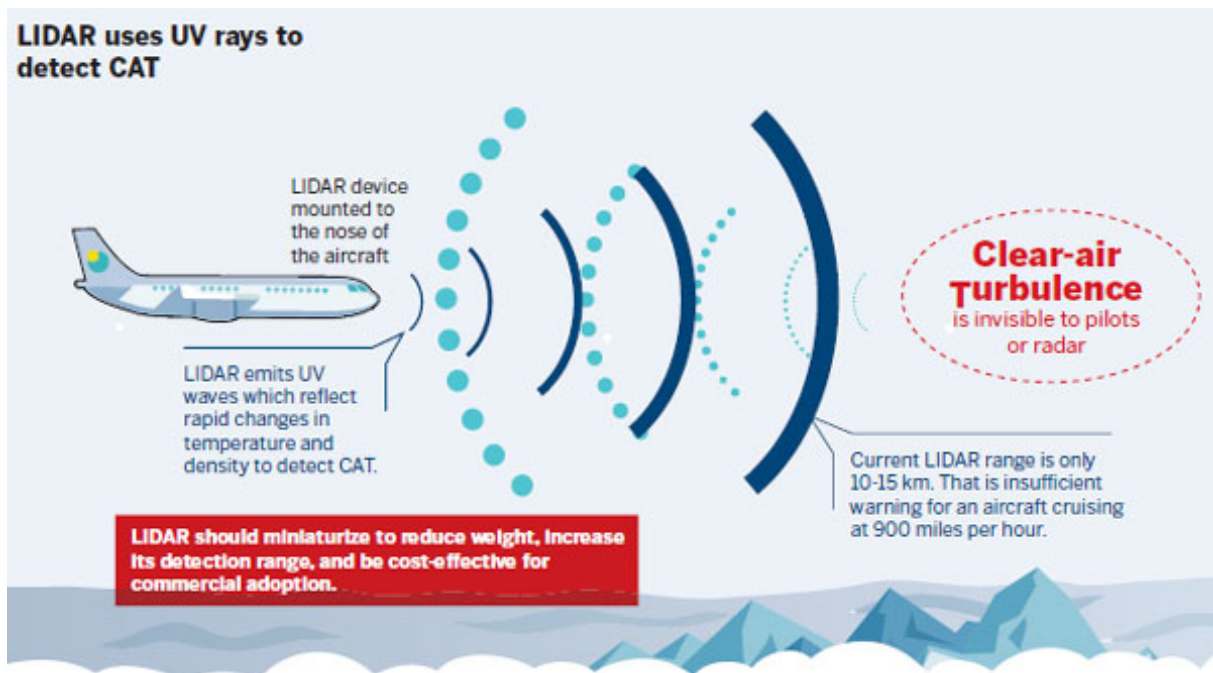


Figura 2.6: Sistema LIDAR [57].

- Estudos Climatológicos:

Transmitem inúmeras informações sobre um determinado assunto. Quando aplicados à turbulência, podem nos fornecer dados e análises sobre a temporalidade, sazonalidade, intensidade, localidade, altitude e horário de ocorrência do fenômeno, para fins de desenvolvimento de novos estudos e tecnologias.

- E-TURB Radar ("Enhanced Turbulence Radar"):

Radar meteorológico desenvolvido pela National Aeronautics and Space Administration (NASA) que se utiliza de algoritmos de detecção de turbulência embutidos em sua dinâmica de funcionamento. Os algoritmos detectam desvios de velocidades Doppler utilizando *scans* de antenas de radar múltiplas, computando a resposta de antecipação ao encontro do fenômeno e gerando um *display* em tempo real da localidade e da intensidade do fenômeno através de diferentes tipos de cores. A NASA está utilizando esta tecnologia junto com a Delta Airlines. O TAPS ("Turbulence Automatic PIREPS System") é um sistema automático de reportes de turbulência. O sistema envia automaticamente para centros de operação e aeronaves próximas reportes de turbulência. As informações automáticas são baseadas nas acelerações e flutuações que impactam as aeronaves a partir dos limiares dos algoritmos de detecção de turbulência.

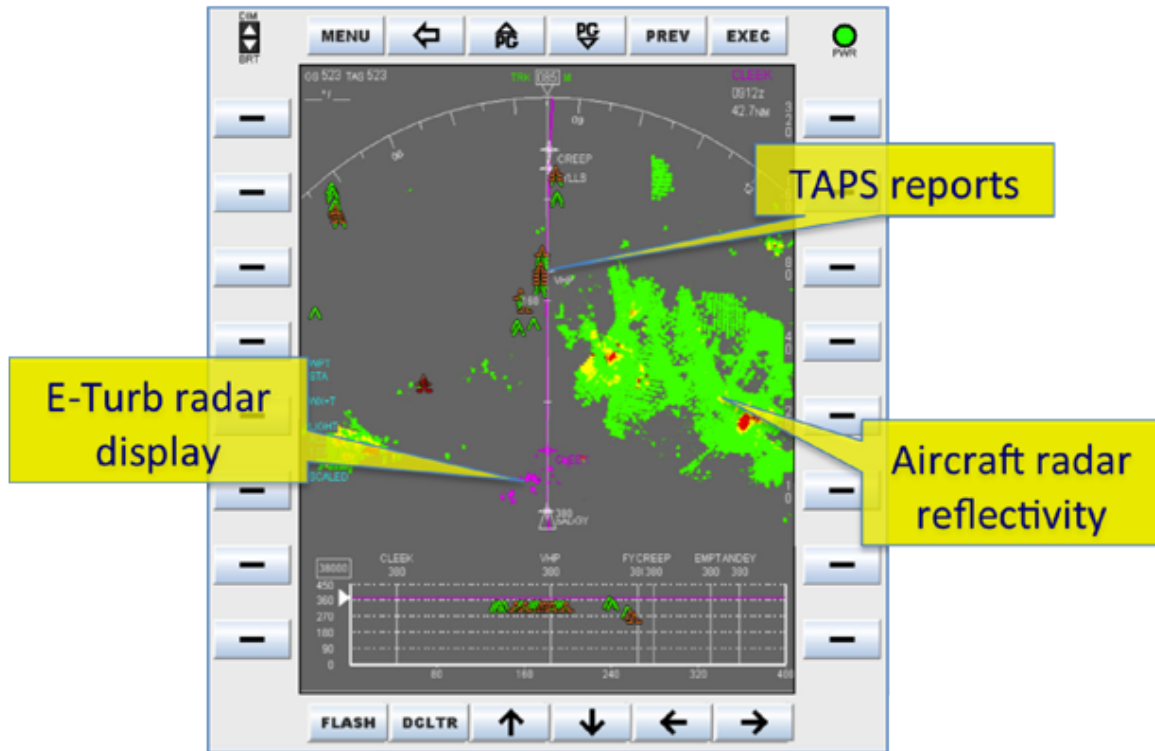


Figura 2.7: Radar ETURB [10].

- *Flight Weather Viewer:*

Aplicativo lançado pela companhia aérea norte-americana Delta Airlines, oferece gráficos de áreas de turbulência e previsões em tempo real para os pilotos. O sistema de dados dos sensores aviônicos das aeronaves da empresa utilizam algoritmos especiais de turbulência combinando dados dos acelerômetros verticais com dados das condições atmosféricas, como inclinação, rotação e velocidade do vento, produzindo assim, reportes de turbulência. Esses reportes são enviados automaticamente para modelos de previsão do tempo, sendo disponibilizados em tempo real no aplicativo. Alertas sobre ameaças de turbulência em rota podem ser enviados pelos pilotos da empresa no formato de notificações em áudio e visuais, sinalizando quando e onde o aviso de apertar cintos deve ser ligado e quando os pilotos necessitam estar no comando. Este aplicativo é personalizado por tipo de aeronave, interpretando que uma aeronave 737 e outra do tipo 767 possuem diferentes impactos ante a turbulência, em razão da diferença de tamanho e peso. A redução da emissão de carbono está na dinâmica do sistema, pois através do reconhecimento de áreas de potencial ameaça de turbulência os pilotos não necessitarão efetuar desvios ou utilizar mais combustível, na procura de melhores velocidades, altitude e condições meteorológicas de voo.



Figura 2.8: Aplicativo Flight Weather Viewer [40].

Sensores, lasers e imagens por satélite podem informar turbulências que são fenômenos naturais. A esteira de turbulência gerada por um avião cria um fluxo de ar que pode durar alguns minutos em baixas altitudes e muitos minutos em altas altitudes, onde a sua dissipação é mais demorada devido ao ar ser mais rarefeito.

2.3 Solução criada usando Aprendizado de Máquina

O ADS-B se comunica constantemente com as outras aeronaves e conseguem trocar informações, mas não informa ao piloto qual categoria de esteira de turbulência está em sua direção. Na aviação a redundância para problemas é muito forte e nunca podemos usar apenas uma tecnologia, mas várias são usadas para garantir o perfeito funcionamento.

Nesse trabalho o uso do ADS-B se tornará uma medida preventiva para acidentes aeronáuticos envolvidos com esteiras de turbulência. Introduzindo técnicas de Inteligên-

cia Artificial é possível de maneira rápida, precisa e automática fornecer ao piloto qual aeronave está ao seu redor e consequentemente saber a sua esteira de turbulência. Automaticamente proverá orientações ao piloto do que fazer para não ser atingido ou não adentrar uma esteira de turbulência muito forte com antecedência de centenas de quilômetros.

Com o uso de técnicas de classificação no *Machine Learning* será possível ensinar ao ADS-B a gerar alertas ao piloto do perigo da esteira de turbulência da aeronave que está se aproximando.

Na figura 2.9 é visto uma aeronave intrusa em amarelo a 500 pés abaixo cruzar a aeronave principal. A solução proposta é que o sistema informe ao piloto qual a categoria da esteira de turbulência está se aproximando e que possa assim tomar suas precauções.



Figura 2.9: Aeronave bem próximo da aeronave principal na tela do ADS-B [35].

Atualmente o ADS-B não informa ao piloto quais as categorias de esteiras de turbulência das aeronaves que estão ao seu redor. Diante desse vazio de informações é que foi pensado em usar técnicas de *Machine Learning* para prover informações precisas de forma inteligente. Sabendo os critérios de separação e do tempo mínimo para decolagem é possível criar métodos computacionais no *Cockpit Display of Traffic Information (CDTI)* do ADS-B para alertar o piloto a manter a separação segura e lhe informar o tempo correto de decolar sem o perigo de entrar em uma esteira turbulência muito forte. Ensinar

ao sistema a alertar o piloto de maneira oral e visual quando o mesmo não respeitar os critérios de separação e de tempo em relação à categoria de esteira de turbulência.

Aeronaves possuem atualmente o ADS-B (Automatic dependent surveillance-broadcast) que permite ao piloto ter informações de posição, velocidade e altitude de outras aeronaves, entre outras informações. O *ADS-B out* transmite a cada segundo para outras aeronaves suas informações de identificação, posição, altitude e velocidade, por meio de um transmissor a bordo. Para a recepção dessas informações em tempo real faz se presente o *ADS-B in*, conforme a figura 2.10. O ADS-B consegue enxergar aeronaves tanto no ar quanto em solo a quilômetros de distância.

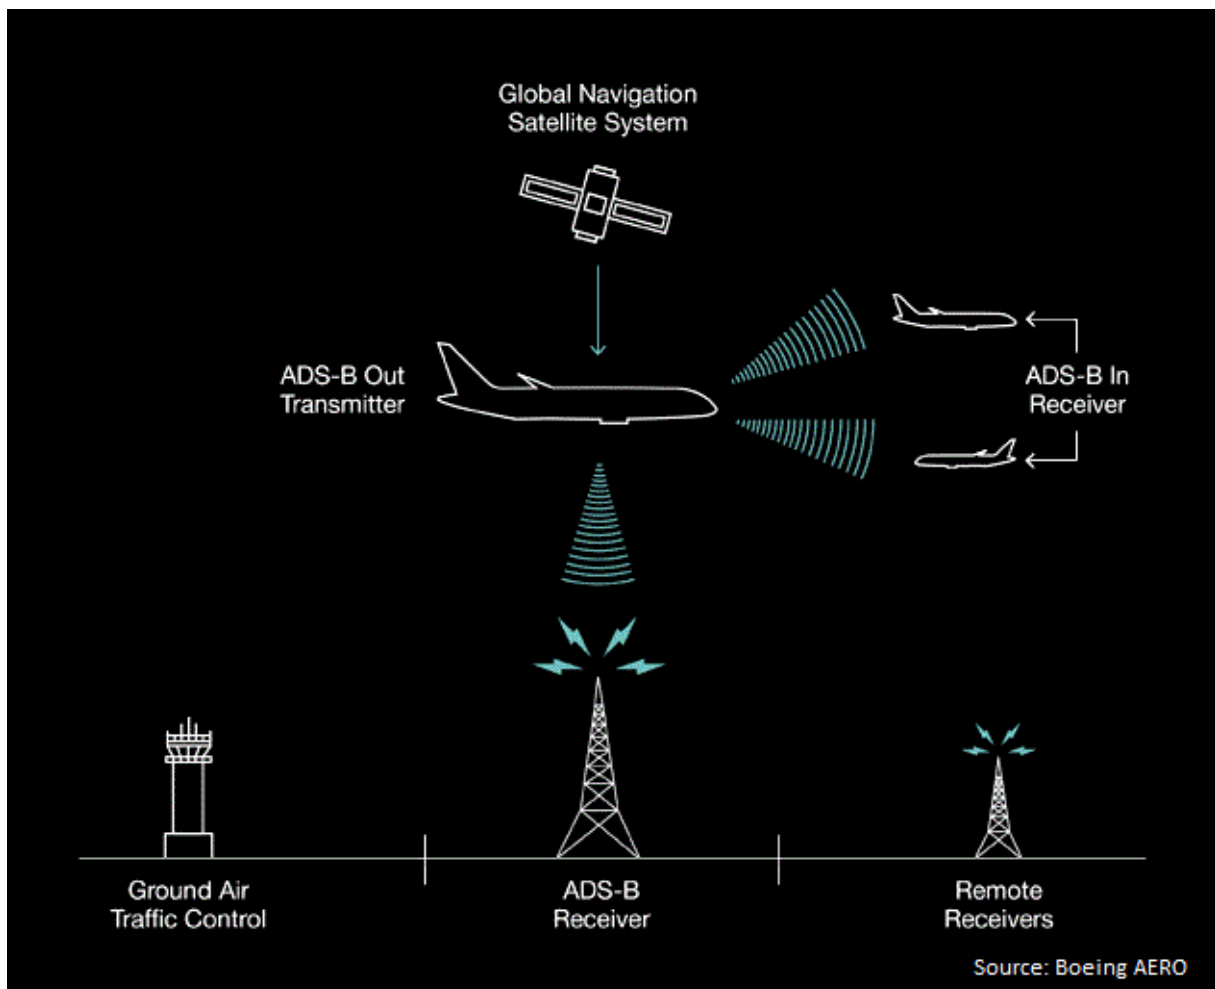


Figura 2.10: Aeronaves se comunicando pelo ADS-B[70].

2.4 Evolução do Sistema de Vigilância de Tráfego Aéreo (ADS-B)

O sistema ADS-B (*Automatic Dependent Surveillance – Broadcast*) é a maior evolução de um Sistema de Vigilância de Tráfego Aéreo.

"Automatic" – está sempre ligado e não requer intervenção do operador.

"Dependent" – depende de dados providos pela aeronave para vigilância.

"Surveillance" – fornece dados de vigilância similares aos do radar secundário.

"Broadcast" – Transmite continuamente a posição da aeronave e outros dados para qualquer aeronave, ou estação terrestre equipada para receber os sinais ADS-B[35]

Antes dos anos 2000, as tecnologias de controle de tráfego aéreo tiveram progresso apenas do ponto de vista dos controladores. Essa abordagem, ainda que bem sucedida, servia apenas para locais onde existiam controladores aéreos (ELOFSON et al., 2018).

Portanto, a necessidade de alguma tecnologia que pudesse ser implantada em ambas as pontas (controlador e aeronave) se tornou cada vez maior, principalmente considerando-se que com o desenvolvimento da aviação mundial, o tráfego aéreo se tornou mais intenso em áreas que eram cobertas pelo controle de tráfego aéreo. Para resolver esse problema, a *Federal Aviation Administration (FAA)* lançou em 2002 a primeira versão do *automatic dependent surveillance — broadcast* (ADS-B). Adicionalmente, lançou um padrão para transponders que suportariam o ADS-B (Mode S 1090 MHz ES [extended squitter]). Vale ressaltar que “[...] nesse contexto, enquanto tecnologia, o ADS-B é uma atualização do SSR, o qual se espera ser inutilizado e dar lugar ao ADS-B como tecnologia principal, já em termos de mensagens, o ADS-B é uma extensão do Mode S” (ELOFSON et al., 2018, p. 2,).

O ADS-B é um sistema que utiliza os meios de comunicação das aeronaves para transmitir informações precisas de posição geográfica, altitude, identificação de voo, registro do avião, velocidade e outras informações que possam ser retiradas da aviônica da aeronave (ICAO, 2007). Além disso, o ADS-B utiliza quadros Mode S para encapsular suas informações, porém, não é necessário nenhum tipo de interrogação para que ocorra o *broadcast* das informações.

Os componentes de um sistema ADS-B podem ser divididos em duas partes: *ADS-B out* e *ADS-B in*. Os dispositivos *ADS-B out* transmitem informações para as estações terrestres e para outras aeronaves equipadas com dispositivos *ADS-B in*.

Já os dispositivos *ADS-B in* possuem a capacidade de receber informações enviadas por componentes *ADS-B out*, sejam elas provenientes de aeronaves ou de estações terrestres. Em suma, o *ADS-B out* tem função de transmissor e o *ADS-B in* de receptor.

Segundo (ELOFSON et al., 2018), as informações transmitidas pelo ADS-B podem ser retransmitidas por torres ATC. O tráfego gerado por esse tipo de serviço é chamado de "traffic information services — broadcast"(TIS-B). As aeronaves podem receber essa informação de forma indireta (TIS-B) ou diretamente e utilizá-las para diversos fins, como por exemplo reduzir a distância entre as aeronaves. Outro serviço oferecido pelo ADS-B, chamado de "flight information services — broadcast"(FIS-B), provê à aeronave informações relativas ao tempo ou outras informações como "air travel information service"(ATIS)⁵ e "notes to airmen"(NOTAMS)⁶ (FAA, 2010).

A Administração Federal de Aviação (FAA) possui um planejamento de modernização da aviação civil americana chamado de *NextGen*, cujo objetivo é “[...] aumentar a segurança, eficiência, capacidade, previsibilidade e resiliência da aviação americana.” (FAA, 2018b, s.p., tradução nossa). Uma das diretivas do NextGen é que as aeronaves que operam no espaço aéreo norte americano possuam equipamentos com suporte ao *ADS-B out* até 10 de janeiro de 2020 (FAA, 2018a).

No Brasil, em 2013, a Agência Nacional de Aviação Civil (ANAC) publicou uma emenda definindo a obrigatoriedade no uso de transponders Mode S nas aeronaves que operam exclusivamente no Brasil (ANAC, 2018). Em 2015, o Departamento de Controle do Espaço Aéreo (DECEA) anunciou a finalização da infraestrutura para operação do ADS-B na Bacia de Campos. Foram instaladas seis estações receptoras dos sinais ADS-B, sendo quatro sobre plataformas marítimas, no oceano Atlântico, e duas em terra firme (DECEA, 2018) [42].

2.4.1 Generalidades do ADS-B

Similar ao ADS-B, também existem sistemas ADS-C que se diferencia do ADS-B na forma como os dados são transmitidos. Enquanto o sistema ADS-B transmite as informações de forma que qualquer receptor compatível pode fazer a leitura dos dados das aeronaves, o sistema ADS-C utiliza um sistema de transmissão fechado, onde apenas os assinantes podem receber as informações. Isso diferencia o sistema ADS-B (broadcast) do sistema ADS-C (contract). Os sistemas ADS-C utilizam comunicação via satélite para a transmissão ou retransmissão dos dados das aeronaves, e como comunicações via satélite têm um elevado custo, estas somente são feitas por contrato [35].

Em termos de tecnologia, o sistema ADS-B é utilizado por aeronaves para enviar a todos no espaço aéreo algumas informações, tais como: identificação, localização, altitude, destino, velocidade e outras. Para obter essas informações, pode-se utilizar instrumentos da própria aeronave ou algum sistema de navegação por satélite *Global Navigation Satellite System (GNSS)*, como por exemplo o sistema de posicionamento *Global Position System (GPS)*. Essas informações são enviadas em forma de "broadcast", sem a interven-

ção de sistemas terrestres. Para aeronaves pequenas, a potência de transmissão mínima é de 75W, enquanto aeronaves grandes possuem um mínimo de 125W e ambas possuem uma potência máxima de 500W (FRANCIS et al., 2011). As estações terrestres recebem essas informações e mostram nas telas dos controladores de tráfego aéreo. Qualquer unidade equipada com ADS-B, seja ela terrestre ou aérea, pode receber essas informações.

O ADS-B enquanto mensagem está encapsulado em um quadro de resposta do Mode S, mas possui um comportamento diferente em relação a interrogação e resposta do Mode S. O sistema ADS-B envia suas mensagens em modo *broadcast*, sem que haja necessidade de uma interrogação, diferente dos modos de interrogação do *Secondary Surveillance Radar (SRR)*. Uma mensagem ADS-B encapsulada em um quadro Mode S possui um preâmbulo no mesmo formato da resposta Mode S, porém no campo *downlink format* é enviado o valor 17, especificando que os dados contidos naquela informação devem ser encarados como uma mensagem ADS-B.

Os aviões podem receber informações de posição, velocidade e altitude através do satélite e enviá-las em broadcast através de um quadro de resposta Mode S. Os aviões podem tanto transmitir (ADS-B out), quanto receber (ADS-B in) essas mensagens. Já a estação terrestre pode apenas receber (ADS-B in) essas informações. As mensagens ADS-B possuem o campo *data* que pode representar vários tipos de mensagens ADS-B, ou seja, existe um identificador para cada tipo de serviço ADS-B, TIS-B, *military*, FIS-B e dentro do serviço ADS-B existem vários tipos de mensagens que representam informações diferentes. Esses tipos são identificados pelos primeiros 5 bits do campo *data* e estão especificados na Tabela 2 (SUN, 2018a). A mensagem do tipo *aircraft identification* serve para informar a identificação da aeronave, o *surface position* traz informações de latitude e longitude de aeronaves em terra, os tipos *airborne position* trazem informações de posição da aeronave provenientes ou da aviação da aeronave ou de um sistema GNSS, o tipo *airborne velocities* informa a velocidade atual da aeronave [42]. A figura 2.11 mostra as antenas externas do ADS-B em um aeronave e a figura 2.12 é o CDTI (Cockpit Display of Traffic), em que o piloto tem em sua própria cabine as informações do ADS-B.

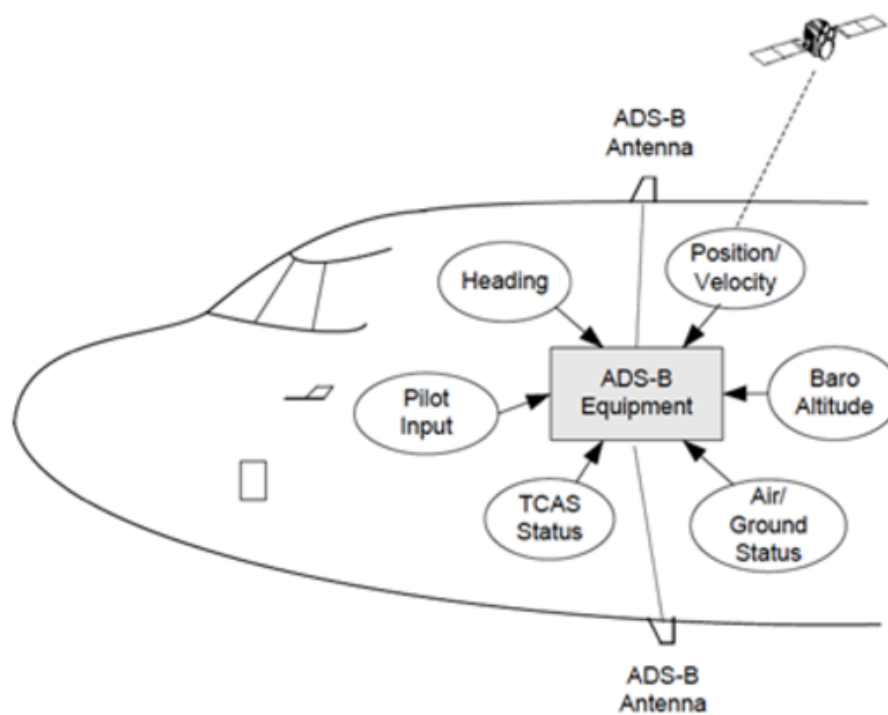


Figura 2.11: Antenas ADS-B [23].

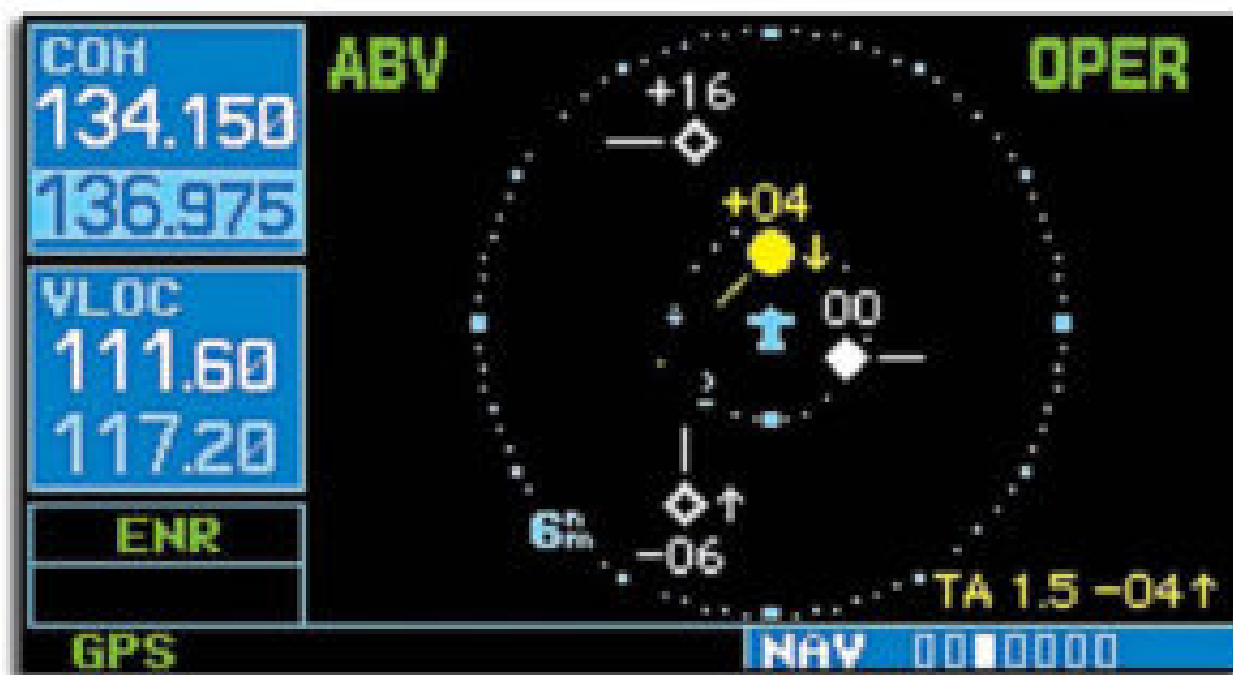


Figura 2.12: Tráfego ADS-B exibido em um GNS com montagem em painel da Garmin [39].

A figura 2.13 representa a própria aeronave azul claro no centro da tela da figura 3.10.




Figura 2.13: Símbolo que representa a propria aeronave na tela do ADS-B.

A figura 2.14 representa um diamante ôco branco que é exibido na figura 3.10 do Tráfego do ADS-B. Esse diamante significa "TRÁFEGO NÃO INTRUSO, 600 PÉS ABAIXO E SUBINDO".




Figura 2.14: Símbolo que representa uma aeronave não intrusa em relação a aeronave no centro da tela do ADS-B.

A figura 2.15 representa um círculo âmbar cheio que é exibido na figura 3.10 do Tráfego do ADS-B. Esse círculo significa "AVISO DE TRÁFEGO INTRUSO, 400 PÉS ACIMA E DESCENDO".




Figura 2.15: Símbolo que representa uma aeronave intrusa em relação a aeronave no centro da tela do ADS-B.

2.5 *Compact Position Reporting (CPR)*

As mensagens de localização (latitude e longitude) no sistema ADS-B são codificadas através de um formato chamado *Compact Position Reporting (CPR)*. De forma geral, a ideia por trás do CPR é possibilitar o envio de coordenadas (latitude e longitude) com maior precisão, utilizando menos bits (ICAO, 2002). Para entender de forma simplificada o funcionamento do CPR, imagine que o mundo possa ser dividido em 16 quadrados, imagine que o mundo possa ser dividido em 16 quadrados, como mostrado na Figura 9.

Esses quadrados são divididos em cores que são representadas por 2 bits, sendo elas amarelo (00), azul (01), vermelho (10) e verde (11). Os blocos de mesma cor podem ser interpretados como a posição global da aeronave. Dentro de cada bloco de cores, existe uma posição local que é codificada por 2 bits. Suponha que um avião que está no primeiro quadrado verde da parte superior esteja se movimentando para o bloco à sua direita. Primeiramente o avião enviou uma mensagem com os bits 1100 que significa que a aeronave está globalmente localizada no bloco verde 11 e na posição local 00. A sua segunda mensagem enviada seria 1101, pois ele continua no bloco verde, mas agora se localiza em outra posição local. Para diminuir o número de bits em cada mensagem, utiliza-se a seguinte estrutura: os dois últimos bits definem a posição local do avião e a combinação do primeiro dígito retirado de duas mensagens define a localização global (SUN, 2018b).

Os algoritmos de codificação CPR são mais complexos do que o exemplo dado anteriormente e utilizam 17 bits para codificar as posições, mas o princípio é muito similar. Em suma, o CPR compacta as mensagens de forma que vários bits de ordem superior, que são normalmente constantes por longos períodos de tempo, não sejam transmitidos em todas as mensagens. Por exemplo, em uma representação binária direta de latitude, um bit designaria se a aeronave está no hemisfério norte ou sul. Este bit permanece constante por um longo tempo, possivelmente a vida inteira da aeronave. Enviar repetidamente esse bit em todas as posições da aeronave, significaria uma redundância desnecessária dessa informação (ICAO, 2002).

Como os bits de ordem mais alta não são transmitidos, vários locais na Terra produzirão a mesma posição codificada. Se apenas uma mensagem de posição fosse recebida, a decodificação envolveria ambiguidade sobre qual das várias soluções é a localização correta da aeronave. A técnica de CPR permite que um sistema receptor determine a localização da aeronave, sem ambiguidade. Isso é feito pela codificação de duas mensagens que diferem ligeiramente. Os dois formatos, chamados de *even-format* e *odd-format*, são transmitidos alternadamente. Após a recepção de ambos os tipos dentro de um curto período, o sistema receptor pode determinar a localização da aeronave sem ambiguidades (ICAO, 2002) [46].

2.6 Considerações Finais

As abordagens estudadas compartilham o objetivo comum de resolver o problema de esteiras de turbulência levando em consideração informações sobre as aeronaves no espaço aéreo. Em geral estas abordagens se diferenciam entre si no que se refere aos métodos empregados e a automação das informações geradas ao piloto. No trabalho proposto, são utilizados dados de categorias de esteiras de turbulência para manter uma separação mínima e um tempo seguro para decolagem. Mais especificamente, é utilizado algoritmos de Aprendizado Supervisionado para realizar alertas aos pilotos em sua própria cabine. A grande vantagem da solução dessa monografia com relação às outras vistas é que esta pode gerar alertas sonoros, visuais, podendo assim, orientar o piloto na sua tomada de decisão em voo, na decolagem e no pouso com o uso do Aprendizado de Máquina.

A abordagem proposta difere das abordagens da seção 2.1 dado que usam servidores em terra e criam outros sistemas. Na solução proposta, será utilizado o próprio ADS-B da aeronave com o uso do Aprendizado de Máquina para gerar alertas e com isso orientar o piloto. O que mais se assemelha seria a exibição de um símbolo apontando a esteira de turbulência de outra aeronave. A abordagem também difere dos trabalhos estudados na

seção 2.2, pois essas abordagens se referem a turbulências atmosféricas no geral e sabido que a esteira de turbulência é gerada pela própria aeronave .

Capítulo 3

Fundamentação Teórica

Este capítulo descreverá os fundamentos teóricos que compreendem conceitos sobre Aprendizado de Máquina e suas subcategorias.

Para construir a solução aqui definida, será utilizado técnicas de classificação de Aprendizado de Máquina para classificar as aeronaves e informar na tela do ADS-B qual a categoria de esteira de turbulência.

3.1 Aprendizado de Máquina

Subcampo da inteligência artificial, o aprendizado de máquina é a área que engloba o estudo e a construção de sistemas inteligentes a partir de dados. Após efetuado o aprendizado, também denominado treinamento, um sistema pode ser utilizado para classificar ou estimar saídas para instâncias desconhecidas. Fornece a computadores a capacidade de aprenderem sem serem explicitamente programados. Aprendizado de Máquina tem como método analisar os dados que automatizam a criação de modelos. É um campo da inteligência artificial focado na lógica que sistemas podem aprender com os dados, apontar padrões e decidir com a mínima interferência humana [32]. Dessa forma, será utilizado ferramentas capazes de transformar esses dados em alertas inteligentes para o piloto utilizar no processo de tomada de decisões.

3.1.1 Aprendizado Supervisionado - Classificação

O método utilizado nesse trabalho é o de aprendizado supervisionado em que o algoritmo é treinado por meio de dados rotulados, como uma entrada na qual a saída requerida é sabida. Por exemplo, o ADS-B poderia ter pontos de dados rotulados como “P” (perigoso) ou “N” (não perigoso).

O aprendizado supervisionado é comumente empregado em aplicações nas quais dados históricos preveem eventos futuros prováveis. Por exemplo, ele pode alertar o piloto com antecedência que uma aeronave com categoria esteira de turbulência muito forte está em sua direção e antecipar as precauções para evitar um acidente.

O programa é “treinado” sobre um conjunto de dados pré-definidos. Baseado no treinamento com os dados pré-definidos, o programa pode tomar decisões precisas quando recebe novos dados. Posteriormente, começa a aprender por conta própria, adquire conhecimento de acordo com as situações que são solucionadas, ou seja, se um problema surgir novamente o mesmo replica a solução e passa a solucionar sozinho o problema.

A aprendizagem de máquina, como mostrado na Figura 3.1, utiliza técnica de a aprendizado supervisionado, que treina um modelo a partir de dados conhecidos de entrada e saída para que ele possa prever resultados futuros.



Figura 3.1: Técnicas de aprendizagem de máquina [17].

O objetivo do aprendizado supervisionado é construir um modelo que faça previsões baseadas em evidências na presença de incerteza. Usando essa técnica, um programa de computador pode “aprender” a partir de observações. Quando exposto a mais observações, o programa melhora seu desempenho preditivo. Especificamente, um algoritmo de aprendizagem supervisionada recebe um conjunto conhecido de dados de entrada e um conjunto conhecido de respostas aos dados de entrada e treina um modelo para gerar previsões razoáveis para novos dados de entrada, como mostrado na Figura 3.2.



Figura 3.2: Modelo geral da Aprendizagem Supervisionada [17].

A aprendizagem supervisionada se divide em duas categorias: classificação e regressão. Na classificação, o objetivo é atribuir classes (ou rótulos) a um conjunto finito de dados.

Prever se um indivíduo terá ou não certa doença dentro de um ano é um problema de classificação, com possíveis classes verdadeiro ou falso. Os algoritmos de classificação usualmente se aplicam a valores de resposta nominais. Na regressão, o objetivo é prever medidas contínuas de uma observação. Ou seja, as variáveis de resposta são números reais. Suas aplicações incluem previsão de preços de ações, consumo de energia ou incidência de eventos [17].

A classificação é uma subcategoria de aprendizagem supervisionada. A classificação consiste em atribuir um rótulo para a saída a partir de determinada entrada. Sistemas de classificação são usados geralmente quando as previsões são de natureza distinta, ou seja, um simples “sim ou não”. Exemplo: Mapeamento de uma categoria de esteira de turbulência e classificação como super, pesada, leve e média.

Os principais algoritmos de aprendizagem supervisionada criam modelos que permitem a classificação, para variáveis categóricas [48]. Para avaliar o modelo obtido, normalmente se separa uma parte dos exemplos existentes para realizar testes, de preferência não os utilizando durante o processo de treinamento para evitar o sobre-ajuste, ou "overfitting". Esse fenômeno ocorre quando o modelo descreve muito bem o conjunto utilizado para treinamento, mas tem baixa capacidade de prever novas entradas. É importante ressaltar que os dados inerentemente apresentam desvios causados por fatores aleatórios, e os algoritmos devem minimizar a influência desses desvios na geração dos modelos.

Para classificadores, a técnica mais utilizada para a avaliação consiste em comparar os valores de saída obtidos com o modelo treinado, utilizando os exemplos de teste como entrada, com os valores de saída existentes nesses exemplos.

Na prática, não existe uma convenção quanto aos valores mínimos para estabelecer a qualidade do modelo, sendo esse um critério totalmente dependente do problema a ser resolvido e dos objetivos a serem atendidos por esse modelo. Porém, em se tratando de aprendizado de máquina, sempre se espera que o modelo treinado apresente uma taxa de acerto superior a um conjunto de escolhas aleatórias, o que demonstra que o modelo aprendeu com os exemplos fornecidos [61].

Nas próximas subseções será mostrado os algoritmos de classificação usados no Aprendizado de Máquina para a realização dos testes.

3.2 *Naive Bayes*

Técnica de classificação apoiado na independência entre os preditores. Por exemplo, um avião pode ser considerado como algo que voa, grande, e que tem asas. Todas estas atributos contribuem de forma independente para a probabilidade que isto que voa é um avião e é por isso que é chamado de ‘Naive’ (ingênuo). Possui uma velocidade relativamente

alta e precisa de apenas poucos dados para realizar a classificação. O *Naive Bayes* pode ser utilizado para previsões em tempo real. Além disso, o *Naive Bayes* só precisa de um pequeno número de dados de teste para concluir classificações com uma boa precisão para concluir que se é perigoso ou não. *Naive Bayes* sempre usa 100% das informações disponíveis.[16]. A figura 3.3 mostra os atributos x_1 , x_2 e x_3 , em que o $?$ é a classe a ser predita pelo *Naive Bayes*.




Figura 3.3: Técnica de *Naive Bayes* [72].

3.2.1 Aplicações do Algoritmo

Previsões em tempo real: *Naive Bayes* é um classificador de aprendizagem voraz e com certeza rápido. Assim, pode ser usado para fazer previsões em tempo real.

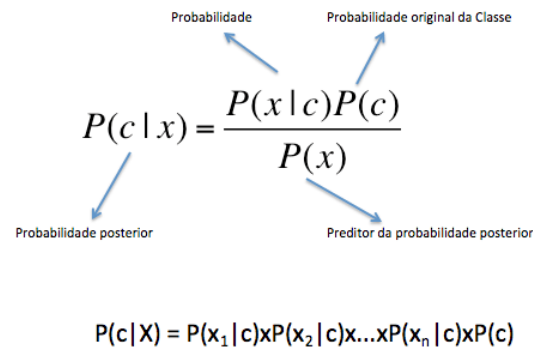
Previsões multiclass: Este algoritmo também é conhecido pela funcionalidade de previsão multiclass. Aqui podemos prever a probabilidade de múltiplas classes das variáveis-alvo.

Classificação de textos/Filtragem de spam/Análise de sentimento: classificadores *Naive Bayes* utilizados principalmente em classificação de textos (devido a um melhor resultado em problemas de classes múltiplas e regra de independência) têm maior taxa de sucesso em comparação com outros algoritmos. Como resultado, é amplamente utilizado na filtragem de spam (identificar spam) e Análise de Sentimento (em análise de mídia social, para identificar sentimentos positivos e negativos dos clientes).

Sistema de Recomendação: o classificador e a filtragem colaborativa *Naive Bayes* em conjunto constroem um sistema de recomendação que utiliza técnicas de Aprendizado de Máquina e mineração de dados para filtrar a informação invisível e prever se um usuário gostaria de um determinado recurso ou não [58].

3.2.2 Equação Matemática

O teorema de Bayes fornece uma forma de calcular a probabilidade posterior $P(C | X)$ a partir de $P(C)$, $P(x)$ e $P(X | c)$.



The diagram shows the equation $P(c | x) = \frac{P(x | c)P(c)}{P(x)}$ with four blue arrows pointing from labels to the terms in the equation:

- An arrow from "Probabilidade" points to $P(c | x)$.
- An arrow from "Probabilidade original da Classe" points to $P(c)$.
- An arrow from "Probabilidade posterior" points to $P(x | c)$.
- An arrow from "Preditor da probabilidade posterior" points to $P(x)$.

$$P(c | X) = P(x_1 | c) \times P(x_2 | c) \times \dots \times P(x_n | c) \times P(c)$$

Figura 3.4: Equação Matemática de Naive Bayes [58].

Acima,

$P(c | x)$ é a probabilidade posterior da classe (c , alvo) dada preditor (x , atributos).

$P(c)$ é a probabilidade original da classe.

$P(x | c)$ é a probabilidade que representa a probabilidade de preditor dada a classe.

$P(x)$ é a probabilidade original do preditor.

É calculado um vetor de probabilidades a priori dividindo o número de documentos de cada classe pelo tamanho da coleção. Ao final do treinamento é estimada uma matriz de probabilidades condicionais através da frequência relativa dos termos nos documentos que pertencem a uma determinada classe. Para evitar que essa estimativa seja nula para uma combinação de termo e classe que não ocorra na coleção de treinamento, é usada uma suavização de Laplace [Manning et al. 2008] que incrementa cada contagem. A função de classificação recebe como parâmetros, além do documento de teste, o conjunto de classes, o vocabulário e as probabilidades estimadas no treinamento. Para cada classe, a probabilidade a posteriori é calculada somando o logaritmo da probabilidade a priori com os logaritmos das probabilidades condicionais de cada termo do documento de teste. O documento então é rotulado com a classe que obtiver a maior probabilidade a posteriori [31]. O algoritmo 1 representa o pseudocódigo do *Naive Bayes* [43].

Algorithm 1 Pseudocódigo do algoritmo *Naive Bayes*

```
TRAINMULTINOMIALNB( $\mathbb{C}, \mathbb{D}$ )
1   $V \leftarrow \text{EXTRACTVOCABULARY}(\mathbb{D})$ 
2   $N \leftarrow \text{COUNTDOCS}(\mathbb{D})$ 
3  for each  $c \in \mathbb{C}$ 
4  do  $N_c \leftarrow \text{COUNTDOCSINCLASS}(\mathbb{D}, c)$ 
5      $\text{prior}[c] \leftarrow N_c / N$ 
6      $\text{text}_c \leftarrow \text{CONCATENATETEXTOFALLDOCSINCLASS}(\mathbb{D}, c)$ 
7     for each  $t \in V$ 
8     do  $T_{ct} \leftarrow \text{COUNTTOKENSOFTERM}(\text{text}_c, t)$ 
9     for each  $t \in V$ 
10    do  $\text{condprob}[t][c] \leftarrow \frac{T_{ct}+1}{\sum_{c'} (T_{ct'}+1)}$ 
11 return  $V, \text{prior}, \text{condprob}$ 

APPLYMULTINOMIALNB( $\mathbb{C}, V, \text{prior}, \text{condprob}, d$ )
1   $W \leftarrow \text{EXTRACTTOKENSFROMDOC}(V, d)$ 
2  for each  $c \in \mathbb{C}$ 
3  do  $\text{score}[c] \leftarrow \log \text{prior}[c]$ 
4     for each  $t \in W$ 
5     do  $\text{score}[c] += \log \text{condprob}[t][c]$ 
6  return  $\arg \max_{c \in \mathbb{C}} \text{score}[c]$ 
```

3.3 Rede Neural Perceptron Multicamadas

Com o aprendizado supervisionado, as redes neurais artificiais devem ser treinadas antes de serem usadas. O treinamento consiste da apresentação dos sinais de entrada e saída à rede [14].

A Perceptron multicamadas produz uma única saída com base em várias entradas. Algoritmo padrão que utiliza retropropagação para atualização dos pesos e possui como parâmetros taxa de aprendizado, momento, declínio e opções para normalização e categorização de atributos numéricos: perigoso ou não para determinada esteira de turbulência [32].

Consiste de várias camadas de elementos simples (ou dois estados) de processamento sigmoidal, ou neurônios que interagem usando conexões ponderadas [Fahlman Hinton, 1987]. Depois de uma camada de entrada, há normalmente qualquer número de camadas intermediárias, ou escondidas, seguida por uma camada de saída [Pal Mitra, 1992; Rosenblatt, 1961]. Perceptron multicamadas (MLP) utiliza uma técnica de aprendizado supervisionado chamado retropropagação para treinamento da rede, é uma modificação da perceptron linear padrão e pode distinguir os dados que não são linearmente separáveis.

Tem a vantagem de ser um método simples, em termos de complexidade computacional. A Figura 2.5 mostra a arquitetura de uma rede neural MLP com uma camada de entrada, 2 camadas escondidas, e uma camada de saída. O vetor $x = [x_1, x_2, \dots, x_n]$ são os sinais de entrada, em que são multiplicados pelos pesos w_1, w_2, \dots, w_n . Posteriormente passa por uma função de ativação monotônica não linear sigmoide que se apresenta crescente com propriedades assintóticas e de suavidade.

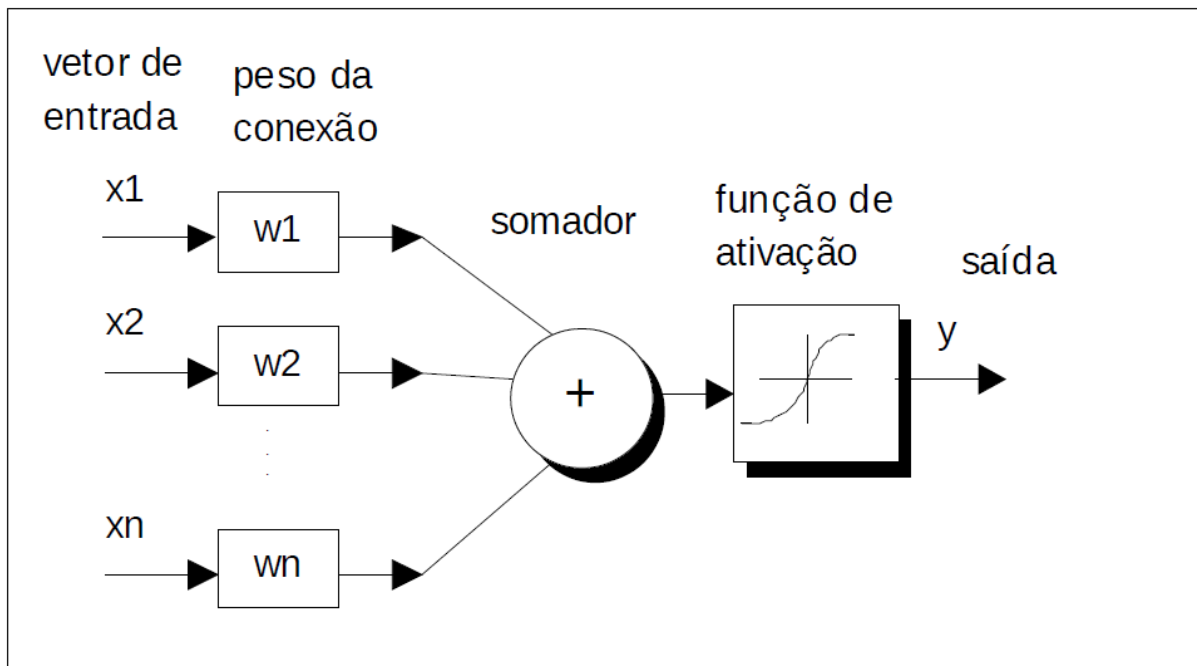


Figura 3.5: Técnicas de MLP[27].

A Retropropagação funciona da seguinte maneira [49]:

Inicialização

- Atribuir valores aleatórios para os pesos e limites;
- Escolha dos valores iniciais influencia o comportamento da rede;
- Na ausência de conhecimento prévio os pesos e limites devem ter valores iniciais aleatórios e pequenos uniformemente distribuídos.

Ativação

- Calcular os valores dos neurônios da camada oculta;
- Calcular os valores dos neurônios da camada de saída.

Treinar os Pesos

- Calcular os erros dos neurônios das camadas de saída e oculta;
- Calcular a correção dos pesos;
- Atualizar os pesos dos neurônios das camadas de saída e oculta.

Iteração

- Repetir o processo a partir do passo 2 até que satisfaça o critério de erro.

O algoritmo 2 representa o pseudocódigo do Perceptron de múltiplas camadas (PMC) [12].

Algorithm 2 Perceptron de múltiplas camadas (PMC) ou *Multilayer Perceptron* (MLP).
Fase de Operação e Treinamento:

Início {Algoritmo PMC – Fase de Operação}

<1> Obter uma amostra $\{ \mathbf{x} \}$;
 <2> Assumir $W_{ji}^{(1)}$, $W_{ji}^{(2)}$ e $W_{ji}^{(3)}$ já ajustadas no treinamento;
 <3> Execute as seguintes instruções:

<3.1> Obter $I_j^{(1)}$ e $Y_j^{(1)}$;

<3.2> Obter $I_j^{(2)}$ e $Y_j^{(2)}$;

<3.3> Obter $I_j^{(3)}$ e $Y_j^{(3)}$;

}

Passo
Forward

 <4> Disponibilizar as saídas da rede, as quais são dadas pelos elementos contidos em $Y_j^{(3)}$

Fim {Algoritmo PMC – Fase de Operação}

Início {Algoritmo PMC – Fase de Treinamento}

<1> Obter o conjunto de amostras de treinamento $\{ \mathbf{x}^{(k)} \}$;
 <2> Associar o vetor de saída desejada $\{ \mathbf{d}^{(k)} \}$ para cada amostra;
 <3> Iniciar $W_{ji}^{(1)}$, $W_{ji}^{(2)}$ e $W_{ji}^{(3)}$ com valores aleatórios pequenos;
 <4> Especificar taxa de aprendizagem $\{\eta\}$ e precisão requerida $\{\epsilon\}$;
 <5> Iniciar o contador de número de épocas $\{\acute{e}poca \leftarrow 0\}$;
 <6> Repetir as instruções:

<6.1> $E_M^{anterior} \leftarrow E_M$;

<6.2> Para todas as amostras de treinamento $\{ \mathbf{x}^{(k)}, \mathbf{d}^{(k)} \}$, fazer:

<6.2.1> Obter $I_j^{(1)}$ e $Y_j^{(1)}$;

<6.2.2> Obter $I_j^{(2)}$ e $Y_j^{(2)}$;

<6.2.3> Obter $I_j^{(3)}$ e $Y_j^{(3)}$;

<6.2.4> Determinar $\delta_j^{(3)}$;

<6.2.5> Ajustar $W_{ji}^{(3)}$;

<6.2.6> Determinar $\delta_j^{(2)}$;

<6.2.7> Ajustar $W_{ji}^{(2)}$;

<6.2.8> Determinar $\delta_j^{(1)}$;

<6.2.9> Ajustar $W_{ji}^{(1)}$;

}

Passo
Backward

<6.3> Obter $Y_j^{(3)}$ ajustado;

<6.4> $E_M^{atual} \leftarrow E_M$;

<6.5> $\acute{e}poca \leftarrow \acute{e}poca + 1$;

Até que: $|E_M^{atual} - E_M^{anterior}| \leq \epsilon$

Fim {Algoritmo PMC – Fase de Treinamento}

3.4 Árvore de decisão C4.5

Método de Aprendizagem de Máquina supervisionada muito utilizado em tarefas de classificação. A aprendizagem de árvores de decisão obtém funções de saída, no qual a função aprendida é exibida por uma árvore de decisão.

Árvores de decisão são ferramentas de aprendizado supervisionado para problemas de classificação. Como o próprio nome da técnica sugere, esta possui como objetivo a construção de uma árvore que represente explicitamente a estrutura do conjunto de dados. Em outras palavras, uma árvore de decisão fornece, através da disposição de seus nós, uma interpretação intuitiva do conjunto de variáveis explicativas para o critério de classificação.

Munido de uma tupla e seus valores para as variáveis independentes, o percurso pela árvore encerrando em uma folha determina o valor da classe para a instância. Os nós são rotulados com um dos atributos e os ramos partindo destes indicam seus valores possíveis. Os valores para os atributos em uma árvore de decisão são variáveis categóricas contínuas.

A métrica mais amplamente utilizada para a seleção de atributos relevantes no processo de construção de uma árvore de decisão é o ganho de informação, cálculo que indica a quantidade de informação ganha após a inserção de um nó na árvore que efetua uma decisão a partir de um atributo, isto é, o ‘benefício’ obtido ao se utilizar este atributo ao invés dos outros no conjunto [32].

Árvore de decisão é um tipo de algoritmo com uma variável alvo pré-definida, muito utilizada em problemas de classificação. Na árvore de decisão, dividimos a população ou amostra em dois ou mais conjuntos homogêneos (ou sub-populações) com base nos divisores/diferenciadores mais significativos das variáveis de entrada [8].




Figura 3.6: Exemplo de Árvore de Decisão [71].

3.4.1 Equação Matemática

A classificação usa a seleção de atributos para determinar qual atributo pertence ao conjunto que melhor se enquadra no nó da Árvore de Decisão. Um critério de seleção de atributos é o Ganho de Informação, utilizado em algoritmos como o C4.5 (J48). O ganho de informação tem como base de medida a entropia. A entropia é dada pela fórmula da imagem 2.7 que determina a quantidade de S que pertence a categoria Cj, podendo ter m valores possíveis:

$$\text{Entropia}(S) = \sum_{j=1}^m - p_j \log_2 p_j$$

Figura 3.7: Fórmula de ganho de informação de Árvore de Decisão [71].

Onde:

S é o conjunto de amostras

m é o número de classes

Pj é a proporção de S pertencente à classe j, tendo então:

$$p_j = \frac{|S_j|}{|S|}$$

Figura 3.8: Fórmula de ganho de Árvore de Decisão[71].

Onde: S_j é a quantidade de exemplos classificados na j-ésima partição;

S é a quantidade total de exemplos do conjunto S.

O algoritmo 3 mostra um algoritmo genérico para construir árvores de decisão, em que S representa o conjunto de exemplos aplicado à árvore, sendo que inicialmente S contém todos os exemplos de treino [30].

Algorithm 3 Algoritmo genérico para construção de árvores de decisão.

if todos os exemplos no atual conjunto de exemplos S satisfazem um critério de parada;

then cria um nodo folha com algum nome de classe e para;

else

escolhe um teste sobre os valores de A , com resultados mutualmente exclusivos e coletivamente exaustivos R_1, \dots, R_k , e cria um ramo, a partir do nodo recentemente criado, para cada teste;

particiona S nos subconjuntos S_1, \dots, S_k , tal que cada S_i , $i=1, \dots, k$, contenha todos os exemplos em S com resultado R_i do teste escolhido;

aplica este algoritmo recursivamente para cada subconjunto S_i , $i=1, \dots, k$; *seleciona um atributo A para ser usado como um atributo de particionamento e cria um nodo como o nome do atributo de particionamento*;

escolhe um teste sobre os valores de A , com resultados mutualmente exclusivos e coletivamente exaustivos R_1, \dots, R_k , e cria um ramo, a partir do nodo recentemente criado, para cada teste;

particiona S nos subconjuntos S_1, \dots, S_k , tal que cada S_i , $i=1, \dots, k$, contenha todos os exemplos em S com resultado R_i do teste escolhido;

aplica este algoritmo recursivamente para cada subconjunto S_i , $i=1, \dots, k$;

return()

3.5 Vizinhos mais Próximos

É um algoritmo de aprendizagem supervisionada usado no campo da Machine Learning. Classificador onde o aprendizado é baseado “no quão similar” é um dado (um vetor) do outro. O treinamento é formado por vetores de n dimensões. No K-Nearest Neighbors (KNN), ele não “compara” o seu novo dado (não classificado) com todos os outros de fato, na verdade ele executa um cálculo matemático para medir a distância entre os dados para fazer sua classificação. Esse cálculo pode ser qualquer um que meça a distância entre dois pontos, como por exemplo: Euclidiana, Manhattan, Minkowski, Ponderada, entre outros [36].

O algoritmo KNN segue alguns passos:

- 1 — Recebe um dado não classificado;
- 2 — Mede a distância (Euclidiana, Manhattan, Minkowski ou Ponderada) do novo dado com todos os outros dados que já estão classificados;
- 3 — Obtém as X (no caso essa variável X é o parâmetro K) menores distâncias;

- 4 — Verifica a classe de cada um dos dados que tiveram a menor distância e conta a quantidade de cada classe que aparece;
- 5 — Toma como resultado a classe que mais apareceu dentre os dados que tiveram as menores distâncias;
- 6 — Classifica o novo dado com a classe tomada como resultado da classificação.




Figura 3.9: Exemplo dos passos do KNN [36].

A imagem 3.9, representa o processo de um dado não classificado (em vermelho) e todos os seus outros dados já classificados (amarelo e roxo) cada um com sua classe (A e B). Então, se calcula a distância do seu novo dado com todos os outros pra saber quais estão mais próximos (quais tem as menores distâncias), logo isso pega-se 3(ou 6) dos dados mais próximos e verifica qual é a classe que mais aparece, no caso dessa imagem, os dados mais próximos do novo dado são aqueles que estão dentro do primeiro círculo (de dentro pra fora), e ali dentro há 3 outros dados (já classificados), com isso verifica-se qual é a classe predominante ali dentro, sendo o roxo, pois há 2 bolinhas roxas e apenas 1 amarela, logo esse novo dado que antes não estava classificado, agora ele será classificado como roxo [36].

3.5.1 Distância Euclidiana

Para realizar o cálculo da distância entre dois pontos (nova amostra e todos os outros dados no *dataset*) é muito utilizado a distância euclidiana.

Fórmula da distância euclidiana:

Distância entre duas instâncias \mathbf{p}_i e \mathbf{p}_j definida como:

$$d = \sqrt{\sum_{k=1}^n (p_{ik} - p_{jk})^2}$$

\mathbf{p}_{ik} e \mathbf{p}_{jk} para $k = 1, \dots, n$ são os n atributos que descrevem as instâncias \mathbf{p}_i e \mathbf{p}_j , respectivamente

Figura 3.10: Fórmula Euclidiana [36].

O Algoritmo 4 aproxima a função-objetivo utilizando o algoritmo *K-Nearest Neighbors* para os casos em que a função objetivo pode ser escrita na forma $f: \mathbb{R} \rightarrow V$, sendo V o conjunto finito $\{v_1, \dots, v_s\}$ [61].

Algorithm 4 Pseudocódigo k-Nearest Neighbors.

Algoritmo de treinamento

Cada exemplo de treinamento $\langle x, f(x) \rangle$ deve ser adicionado à lista exemplos treinamento

Algoritmo de classificação:

Dada uma instância X_q a ser classificada:

Com X_1, \dots, X_k representando as K instâncias da lista exemplos treinamento que são mais próximas de X_q

return

$$\hat{f}(x_q) \leftarrow \operatorname{argmax}_{v \in V} \sum_{i=1}^k \delta(v, f(x_i))$$

onde $\delta(a, b) = 1$ se $a = b$ e $\delta(a, b) = 0$ se $a \neq b$

Como coordenadas no espaço aéreo (*longitude*, *latitude*, *altitude*) são utilizadas na representação de uma posição de voo, a medida de distância que naturalmente seria utilizada é a *distância Euclidiana* (distância geográfica) [76], representada pela Equação 3.1.

$$distance(p_1, p_2) = \sqrt{(p_2.x - p_1.x)^2 + (p_2.y - p_1.y)^2 + (p_2.z - p_1.z)^2} \quad (3.1)$$

onde as coordenadas $p_1(x, y, z)$ e $p_2(x, y, z)$ representam as posições de voo p_1 e p_2 num sistema de coordenadas cartesianas [73], respectivamente.

Assim, antes do cálculo de distância entre duas posições de voo, é necessário converter suas coordenadas do sistema esférico de coordenadas para o sistema de coordenadas cartesianas. O algoritmo 5 descreve o processo de conversão para o sistema cartesiano [77].

Algorithm 5 Conversão de uma posição de voo no sistema esférico de coordenadas p para o sistema de coordenadas cartesiano.

```

1: procedure CONVERTTOCARTESIANCOORDINATES( $p$ )           ▷ Longitude, latitude e
   altitude são abreviados para lon., lat. and alt.
2:    $p.x \leftarrow p.alt \times \cos(p.lat) \times \sin(p.lon)$ 
3:    $p.y \leftarrow p.alt \times \sin(p.lat)$ 
4:    $p.z \leftarrow p.alt \times \cos(p.lat) \times \cos(p.lon)$ 
5:   return  $p(x, y, z)$ 

```

3.6 Pré-Processamento dos Dados

Dados provenientes de fontes reais geralmente necessitam de um pré-processamento a fim de serem utilizados pelas técnicas de aprendizado de máquina previamente apresentadas. As etapas mais importantes nessa etapa são a limpeza e seleção de variáveis e a amostragem [38],[50].

3.6.1 Valores incorretos

Valores incorretos podem causar distorções nos modelos obtidos, pois, em geral, os algoritmos de aprendizado de máquina assumem que todos os valores utilizados são completamente corretos. A verificação desse tipo de erro deve ser realizada caso os resultados estejam muito diferentes do esperado, ou quando se supõe a priori que os dados possam ser incorretos.

Para encontrar valores potencialmente incorretos em variáveis categóricas, primeiramente se deve examinar as frequências. Utilizar um histograma, por exemplo, permite buscar valores não usuais. No caso de serem poucos os exemplos contendo essas discrepâncias, pode-se examinar um por vez, para verificar se os valores são factíveis. Para casos em que a quantidade de dados analisada é muito grande, deve-se buscar uma ferramenta que realize essa verificação e correção (ou simplesmente uma sinalização para o desenvolvedor) de forma automática.

Essa análise pode requerer familiaridade e experiência com o tipo de dados estudado, e ainda assim, para alguns valores é difícil determinar qual o valor correto, ou esperado, para aquele campo. Quando dados supostamente incorretos ocorrem em pouca frequência e não podem ser interpretados ou substituídos, pode-se considerá-los como dados faltantes.

Já para variáveis contínuas, valores incorretos podem ser detectados como picos em distribuições, representando assim uma discrepância. Caso esses dados estejam prejudicando os resultados, podem ser tratados com a aplicação de filtros. Em casos onde os dados contendo valores incorretos são tão infrequentes que não podem ser detectados facilmente, pode-se mantê-los, pois provavelmente eles não apresentarão relevância no processo de modelagem.

3.6.2 Amostragem

A amostragem é uma técnica utilizada para selecionar um subconjunto com dados relevantes a partir de um conjunto maior de dados. Em algumas aplicações a amostragem é necessária devido ao custo computacional em processar todos os dados disponíveis.

Outra aplicação é para dividir o conjunto de exemplos em conjuntos para treinamento e para teste. Nesse caso, o conjunto de treinamento é utilizado para construir os modelos utilizando as técnicas de aprendizado de máquina e o conjunto de teste é usado para avaliar o modelo gerado, utilizando dados desconhecidos para o modelo.

Em se tratando de amostragem, a grande questão é encontrar um conjunto de dados que seja representativo, ou seja, que tenha as mesmas propriedades de interesse que o conjunto original. A técnica mais simples é a amostragem aleatória, onde a probabilidade de selecionar um exemplo é a mesma para todo o conjunto. Existem, porém, técnicas mais sofisticadas, como a amostragem estratificada, onde o conjunto de dados é dividido em diversas partições de acordo com características dos dados, e então exemplos são escolhidos aleatoriamente dentre cada uma das partições.

Outro aspecto importante é quanto à remoção dos dados do conjunto. A abordagem mais comum é de retirar os exemplos escolhidos do conjunto, de forma que um mesmo exemplo não pode ser escolhido mais de uma vez. Pode-se também optar por não remover os exemplos escolhidos, com possibilidade de serem escolhidos repetidamente[61].

A prática comumente utilizada é de usar a amostragem aleatória, retirando os exemplos escolhidos do conjunto e utilizando uma proporção de 80/20 para exemplos de treinamento e teste, respectivamente. Variações com proporções entre 80/20 e 60/40 são apropriadas para a maioria das aplicações [60].

3.6.3 Classificação

Uma vez o *dataset* tendo sido carregado no *Weka* e feito o pré-processamento dos dados foi possível usar algoritmos classificadores para realizar treinamentos e testes. Foi escolhido o *Cross-Validation* que é um método da Aprendizagem de Máquina que divide um *dataset* em conjuntos de treinos e de testes. Para cada algoritmo escolhido foi utilizado no *Cross-*

Validation a quantidade padrão 10, ou seja, o conjunto de dados é dividido em 10 partes, em que 9 partes ficam para realização do treino e a parte restante para o teste.

Os resultados são mostrados de acordo com o algoritmo de classificação escolhido para possibilitar uma análise de qual algoritmo teve o melhor desempenho.

TP: True Positive - Taxa Média de Verdadeiros Positivos = $TP / (TP + FN)$

Nº de exemplos classificados "YES" que são "YES".

FP: False Positive - Taxa Média de Falsos Positivos = $FP / (FP + TN)$

Nº de exemplos classificados "YES" que são "NO".

TN: True Negative - Taxa Média de Verdadeiros Negativos = $TN / (FP + TN)$

Nº de exemplos classificados "NO" que são "NO".

FN: False Negative - Taxa Média de Falsos Negativos = $FN / (TP + FN)$

Nº de exemplos classificados "NO" que são "YES".

ACURÁCIA = $(TP + TN) / (TP + TN + FP + FN)$

Taxa de acerto.

PRECISÃO = $TP / (TP + FP)$

Mede a qualidade de cada previsão individual.

Taxa de TP : taxa de verdadeiros positivos (instâncias classificadas corretamente como uma determinada classe). Verdadeiros positivos são exemplos rotulados corretamente como positivos.

Taxa FP : taxa de falsos positivos (casos classificados falsamente como uma determinada classe). Falsos positivos referem-se a exemplos negativos incorretamente rotulados como positivo.

Um positivo falso é uma instância de dados em que o modelo que criamos prevê que ela deve ser positiva, mas, ao invés disso, o valor real é negativo. De modo inverso, um negativo falso é uma instância de dados em que o modelo prevê que ela deve ser negativa, mas o valor real é positivo [1].

Uma comparação foi realizada entre os algoritmos e captado a precisão média de cada algoritmo, a Taxa Média de Falsos Positivos (FP), a Taxa Média de Verdadeiros Positivos (TP) e a Acurácia.

A matriz de confusão contém informações muito importantes para o entendimento do resultado do algoritmo, dentre elas:

- a quantidade de instâncias classificadas corretamente;
- a quantidade de instâncias classificadas erroneamente;
- a quantidade de instâncias que o algoritmo acreditava ser de um tipo (yes) e na verdade foram classificadas como (no) ou vice-versa.

A figura 3.11 exemplifica a matriz confusão:

	CLASSE PREDITA	
CLASSE ATUAL	YES	NO
	YES	NO
	TP	FN
	FP	TN

Diagonal de acertos

Figura 3.11: Matriz confusão[18].

3.7 Ambiente de Testes *Weka*

Weka [84], acrônimo para *Waikato Environment for Knowledge Analysis*, é uma coleção de algoritmos e ferramentas de aprendizado de máquina para tarefas de mineração de dados. Atualmente, é considerado como sistema de referência tanto no meio acadêmico quanto comercial pois é open-source além de altamente modular e extensível, permitindo a integração de novos algoritmos com a interface por meio de *plugins* e *Application Programming Interface (APIs)* [32].

Através do Weka é possível utilizar algoritmos de aprendizagem supervisionada de classificação.

Capítulo 4

Modelagem e Aplicação

Neste capítulo serão apresentados conceitos gerais da solução, como: definição da aplicação, entradas e saídas, fontes de dados, organização dos dados, relação entre os dados, entre outros. Os dados da solução serão detalhados conforme suas modelagens e implementações.

A solução proposta pode ser subdividida em duas grandes etapas. Na primeira, dados de categorias de esteiras de turbulência utilizados na separação e do tempo de decolagem. Na segunda etapa, as categorias de esteiras de turbulência são utilizadas no ADS-B com regras de classificação para se obter os resultados esperados.

4.1 Solução Proposta

O sistema obtém como entrada: dados de categorias de esteiras de turbulência. A solução proposta segue os seguintes passos para medir o impacto das esteiras de turbulência aeronáuticos:

1. **Fontes de Dados:** levantamento de dados de categorias de esteiras de turbulência.
2. **Uso do ADS-B:** informações de identificação de aeronaves, sua posição, sua altitude, utilizando técnicas de Aprendizado de Máquina.

4.1.1 Generalidades

Reforçando novamente a definição de esteira de turbulência que é um ar turbulento causado por vórtices de ponta de asa.

Vórtice de ponta de asa: Um padrão circular de corrente de ar criado pelo movimento de um aerofólio através do ar, quando o aerofólio estiver gerando sustentação. À medida que um aerofólio se move através da atmosfera em voo sustentado, uma área de alta

pressão é criada abaixo e uma área de baixa pressão é criada acima dele. O ar fluindo da área de alta pressão para a área de baixa pressão em torno das pontas do aerofólio tende a girar rapidamente em dois vórtices de forma cilíndrica. Esses vórtices fazem parte predominante da esteira de turbulência das aeronaves e sua força de rotação depende do *wing loading*, peso bruto e velocidade da aeronave geradora da turbulência. Os vórtices gerados por aeronaves de médio a grande porte podem ser perigosos para aeronaves menores. INVESTIGAÇÃO E PREVENÇÃO DE ACIDENTES AERONÁUTICOS. MCA 3-6 MANUAL DE INVESTIGAÇÃO DO SIPAER 2017 [20].

Aeronaves voando no espaço *Reduced Vertical Separation Minima (RVSM)* se cruzam no ar por apenas 300 metros e deve se ter cuidado para que a esteira de turbulência gerada por uma aeronave grande não atinja um avião pequeno. Quanto mais pesada e maior a aeronave gerará uma esteira de turbulência mais violenta. A figura 4.1 mostra as maiores aeronaves do mundo, o Airbus A380 e o Antonov 225.



Figura 4.1: Maiores aeronaves do mundo. Categoria J (Super Jumbo) [34].

Foi criada uma categoria especial para o Airbus A380, conhecida como SUPER, que está acima da categoria pesado por conta da enorme esteira de turbulência gerada. As figuras 4.2 e 4.3 têm o intuito de mostrar tão grande é um Airbus A380 em relação a outras aeronaves.



Figura 4.2: Airbus A380 próximo de um Boeing 737-330[75].



Figura 4.3: Airbus A380 próximo de um Airbus A320 [55]

Na fase de decolagem e pouso, aviões se encontram em alto ângulo de ataque e isso maximiza a formação de vórtices fortes.



Figura 4.4: Su-35 com elevado ângulo de ataque [79]

4.2 Fonte de Dados: EUROCONTROL RECAT-EU (*European Wake Turbulence Categorisation and Separation Minima on Approach and Departure*)

Tanto a ICAO (Organização Internacional da Aviação Civil) e a FAA (Administração Federal de Aviação) usam como base para definir as categorias de esteira de turbulência o peso máximo de decolagem das aeronaves.

Foi escolhido como *data set* os dados da Organização Europeia para a Segurança da Navegação Aérea (EUROCONTROL), pois possui a maior base de dados global, criou métricas de vigília avançadas para configurar seis categorias de esteira de turbulência com mínimos de separação, com a finalidade de suportar com segurança um aumento de rendimento na pista em aeroportos da Europa. *RECAT-UE* integra também uma categoria Super Pesado para o Airbus A380 trazendo benefícios a capacidade das pistas de até 8% ou mais durante os períodos de pico de tráfego[26].

4.2.1 Categorias de Esteiras de Turbulência

Para entendermos como funciona as separações seguras e os tempos de decolagem e pouso de aeronaves em relação as esteiras de turbulência existem várias métricas [26].

As separações da ICAO de hoje são baseadas na massa máxima de decolagem (MTOM) certificada e inclui três categorias (ou seja, PESADA, MÉDIA ou LEVE), alocando todas as aeronaves em uma delas. Como as separações são definidas com base no pior caso de cada categoria, isso leva a excesso de separação em muitos casos.

Leader / Follower	A380-800	HEAVY	MEDIUM	LIGHT
A380-800		6 NM	7 NM	8 NM
HEAVY MTOM \geq 136 tons		4 NM	5 NM	6 NM
MEDIUM 7 tons \leq MTOM < 136 tons				5 NM
LIGHT MTOM < 7 tons				

Figura 4.5: ICAO: *categorias de esteiras de turbulência e separação mínima* [26]

Nota 1: O Airbus A380-800 (A388), com uma massa máxima de decolagem na ordem de 560.000 kg, é a maior aeronave de passageiros já inserida no comércio. A aeronave está na categoria de turbulência PESADA, que não possui limite superior definido. Para o A380-800, uma orientação da OACI divulgada em 2008 recomenda um aumento em relação aos mínimos de separação de esteiras de turbulência publicado no Doc 4444 PANS-ATM da ICAO.

Nota 2: Quando uma restrição de turbulência de ativação não é necessária, a separação reverte para o mínimo de separação do radar (MRS): · conforme prescrito pela ICAO como separação mínima por radar (MRS), sendo 3NM (ou 2,5NM sob dadas as condições descritas no Doc 4444), ou; · conforme prescrito pela autoridade ATS apropriada.

Tanto o A346 quanto o B763 estão na atual categoria da ICAO *HEAVY*, enquanto a extensão da asa tem um diferença de mais de 15 metros. Portanto, eles sofrem de separações excessivamente conservadoras quando lideram [26].

4.2.2 Categoria Pesada

A imagem 4.6, mostra que tanto o A346 quanto o B763 estão na atual categoria da ICAO PESADO, enquanto a extensão da asa tem uma diferença de mais de 15 metros. Portanto, eles sofrem de separações excessivamente conservadoras.



Figura 4.6: Comparação do tamanho da aeronave entre AIRBUS A340-600 e BOEING B767-300 [26]

A figura 4.7 mostra uma separação segura, mas conservadora.




Figura 4.7: Distância conservadora da ICAO para o AIRBUS A340-600 e BOEING B767-300 [26]

A figura 4.8 mostra uma separação segura e mais eficiente.




Figura 4.8: Distância mais eficiente e segura também pelo Recat-eu para o AIRBUS A340-600 e BOEING B767-300 [26]

4.2.3 Categoria Média

A imagem 4.9, mostra que tanto o A320 quanto o E145 estão na atual categoria MÉDIA pela OACI, enquanto as suas asas têm uma diferença de mais de 12 metros. Portanto, o A320 sofre de separações mais conservadoras quando seguidor.




Figura 4.9: Comparação do tamanho da aeronave EMBRAER ERJ-145 e AIRBUS A320 [26].

A figura 4.10 mostra uma separação segura, mas conservador para o A320 de acordo com a ICAO.




Figura 4.10: Separação mínima de turbulência da OACI aplicável ao A320 e para o ERJ-145 seguindo A340-600 [26].

A figura 4.11 mostra uma separação segura e mais eficiente de acordo com a Recat-eu.




Figura 4.11: Separação de turbulência de vigília RECAT-EU mínima aplicável a A320 e para ERJ-145 seguindo A340-600 [26].

A solução desse problema trouxe uma categorização muito mais precisa na Europa: RECAT-UE. Ele divide as categorias PESADO e MÉDIO atuais em duas subcategorias e cria um novo SUPER PESADO para o AIRBUS A380.

4.2.4 Novas Categorias de Aeronaves

A figura 4.12 exemplifica as novas categorias de aeronaves.

CAT A	 A124	 A380
CAT B	 A332	 B744
CAT C	 MD11	 B763
CAT D	 B738	 A320
CAT E	 E190	 AT45
CAT F	 SF34	 LJ35

Figura 4.12: Exemplo de novas categorias de aeronaves [26].

Todos os tipos de aeronaves certificadas (de acordo com os designadores da ICAO) antes de 1º de janeiro de 2013 foram designados no esquema RECAT-EU.

A figura 4.13 exemplifica as novas categorias de aeronaves.

'SUPER HEAVY'	'UPPER HEAVY'	'LOWER HEAVY'	'UPPER MEDIUM'	'LOWER MEDIUM'	'LIGHT'
'CAT-A'	'CAT-B'	'CAT-C'	'CAT-D'	'CAT-E'	'CAT-F'
A388	A332	A306	A318	AT43	FA10
A124	A333	A30B	A319	AT45	FA20
(...)	A343	A310	A320	AT72	D328
	A345	B703	A321	B712	E120
	A346	B752	AN12	B732	BE40
	A359	B753	B736	B733	BE45
	B744	B762	B737	B734	H25B
	B748	B763	B738	B735	JS32
	B772	B764	B739	CL60	JS41
	B773	B783	C130	CRJ1	LJ35
	B77L	C135	IL18	CRJ2	LJ60
	B77W	DC10	MD81	CRJ7	SF34
	B788	DC85	MD82	CRJ9	P180
	B789	IL76	MD83	DH8D	C650
	IL96	MD11	MD87	E135	C525
	(...)	TU22	MD88	E145	C180
		TU95	MD90	E170	C152
		(...)	T204	E175	(...)
			TU16	E190	
			(...)	E195	
				F70	
				F100	
				GLF4	
				RJ85	
				RJ1H	
				(...)	

Figura 4.13: Exemplo de lista de tipos de aeronaves atribuídos às categorias RECAT-EU) [26].

4.2.5 Mínimos de separação com base na distância no momento do pouso e da decolagem

Os mínimos de separação aplicáveis entre as categorias de turbulência de esteira RECAT-EU é fornecido na figura 4.14.

RECAT-EU scheme		"SUPER HEAVY"	"UPPER HEAVY"	"LOWER HEAVY"	"UPPER MEDIUM"	"LOWER MEDIUM"	"LIGHT"
Leader / Follower		"A"	"B"	"C"	"D"	"E"	"F"
"SUPER HEAVY"	"A"	3 NM	4 NM	5 NM	5 NM	6 NM	8 NM
"UPPER HEAVY"	"B"		3 NM	4 NM	4 NM	5 NM	7 NM
"LOWER HEAVY"	"C"		(*)	3 NM	3 NM	4 NM	6 NM
"UPPER MEDIUM"	"D"						5 NM
"LOWER MEDIUM"	"E"						4 NM
"LIGHT"	"F"						3 NM

Figura 4.14: Mínimos de separação baseados na distância RECAT-EU WT na aproximação e partida [26].

(*) significa que a separação mínima por radar (MRS), definida em 2,5 NM, é aplicável conforme a ICAO atual doc 4444 disposições.

4.2.6 Mínimos de separação com base no tempo - decolagem

Os mínimos de separação aplicáveis entre as categorias de turbulência de esteira RECAT-EU é fornecido na figura 4.15. Continua sendo opcional implantar localmente parte do esquema RECAT-EU ou aplicar maiores mínimos de separação que os propostos ou optar por uma aplicação progressiva.

RECAT-EU scheme		"SUPER HEAVY"	"UPPER HEAVY"	"LOWER HEAVY"	"UPPER MEDIUM"	"LOWER MEDIUM"	"LIGHT"
Leader / Follower		"A"	"B"	"C"	"D"	"E"	"F"
"SUPER HEAVY"	"A"		100s	120s	140s	160s	180s
"UPPER HEAVY"	"B"				100s	120s	140s
"LOWER HEAVY"	"C"				80s	100s	120s
"UPPER MEDIUM"	"D"						120s
"LOWER MEDIUM"	"E"						100s
"LIGHT"	"F"						80s

Figura 4.15: Mínimos de separação com base no tempo RECAT-EU WT no momento da partida [26].

4.3 Vantagens do ADS-B em relação as Categorias de Esteiras de Turbulência

ADS-B é uma tecnologia de vigilância automática e cooperativa para rastreamento de aviões em tempo real. Aeronaves determinam suas posições através de navegação via satélite e emitem os dados coletados através de uma frequência de rádio. Essas informações podem, então, ser recebidas via estações de Controle de Tráfego Aéreo ou por outras aeronaves, desde que possuam receptores ADS-B e estejam dentro de determinado alcance [13].

Radares e dispositivos ADS-B permitem a visualização de movimentos de aeronaves no espaço aéreo. Ao rastrear a localização das aeronaves e estimar seus posicionamentos futuros, o Controle de Tráfego Aéreo pode atuar na garantia da segurança das operações no espaço aéreo. O sistema ADS-B proporciona melhorias determinantes para a vigilância aérea ao permitir um maior número de amostras e mais parâmetros sobre as aeronaves do que é convencionalmente possível obter com o radar secundário [13].

Dispositivos ADS-B são de menor custo de aquisição e manutenção, e mais eficazes

em áreas de terrenos montanhosos, onde a cobertura por radar é limitada ou inexistente [45].

As informações das aeronaves em voo são enviadas constantemente para estas redes distribuídas de receptores ADS-B que trabalham de forma colaborativa. Dessa forma os dados podem ser acessados de forma livre ou não dependendo da plataforma utilizada, através de *Application Programming Interface* (APIs) para consulta destas informações [13].

O trabalho atual é feito utilizando *WEKA* uma vez que esta oferece a possibilidade de realizar vários experimentos com diversos algoritmos de classificação.

As informações importantes para a solução nesse trabalho são:

- **Status do voo:** horário do voo, horário estimado de chegada, horário real de partida; tempo médio de voo; atraso médio de chegada; distância do voo; entre outros;
- **Detalhes da aeronave:** identificador único da aeronave; tipo da aeronave; entre outros;
- **Detalhes do voo -** posições de voo da aeronave em latitude, longitude e altitude; direção da aeronave; velocidade em relação ao solo; entre outros.

4.4 Fluxogramas das Soluções

As figuras 4.16, 4.17 e 4.18 mostram fluxogramas e têm por objetivo ajudar na compreensão do processo realizado por meio esquemático para exibir a solução desenvolvida.

A figura 4.16 aborda o fluxograma de uma aeronave Airbus A380 (categoria esteira de turbulência Super) decolando. Exibe tomadas de decisão em relação a uma aeronave categoria esteira de turbulência leve aguardar o tempo suficiente para efetuar a decolagem após o A380. Apresenta também como tomada de decisão se o ADS-B consegue alertar o piloto para a presença de uma aeronave Super.

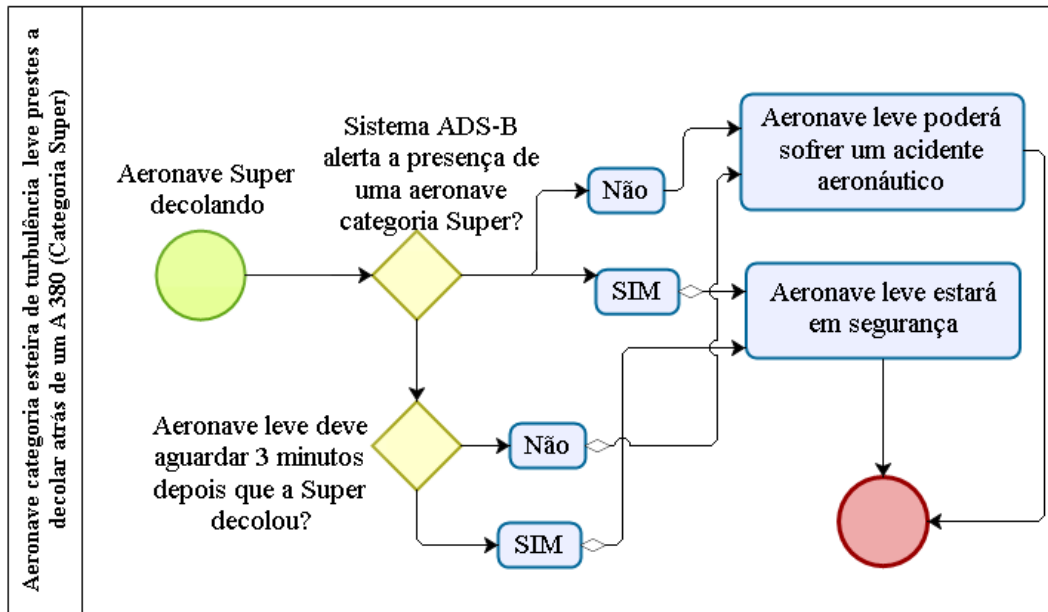


Figura 4.16: Fluxograma após implementação da solução no momento da decolagem usando o ADS-B e técnicas de Machine Learning.

A figura 4.17 aborda o fluxograma de uma aeronave Airbus A380 (categoria esteira de turbulência Super) pousando. Exibe tomadas de decisão em relação a uma aeronave categoria esteira de turbulência leve aguardar a distância suficiente para efetuar o pouso após o A380. Apresenta também como tomada de decisão se o ADS-B consegue alertar o piloto para a presença de uma aeronave Super.

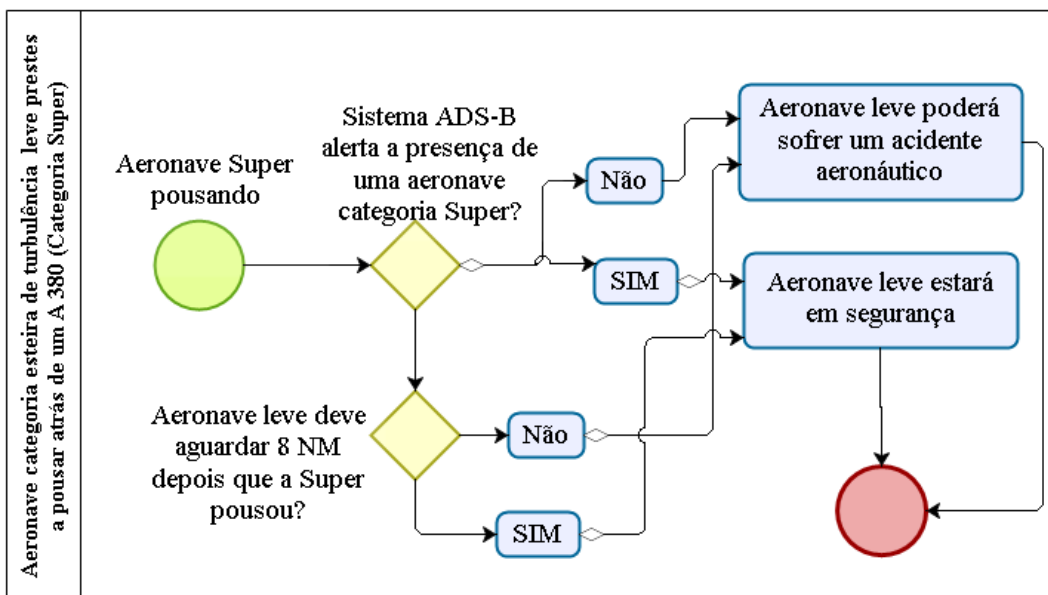


Figura 4.17: Fluxograma após implementação da solução no momento do pouso usando o ADS-B e técnicas de Machine Learning.

A figura 4.18 aborda o fluxograma de uma aeronave Airbus A380 (categoria esteira de turbulência Super) em voo. Exibe tomadas de decisão em relação a uma aeronave categoria esteira de turbulência leve a manter uma separação segura em voo de no mínimo 8 milhas para com o A380. Apresenta também como tomada de decisão se o ADS-B consegue alertar o piloto para a presença de uma aeronave Super.

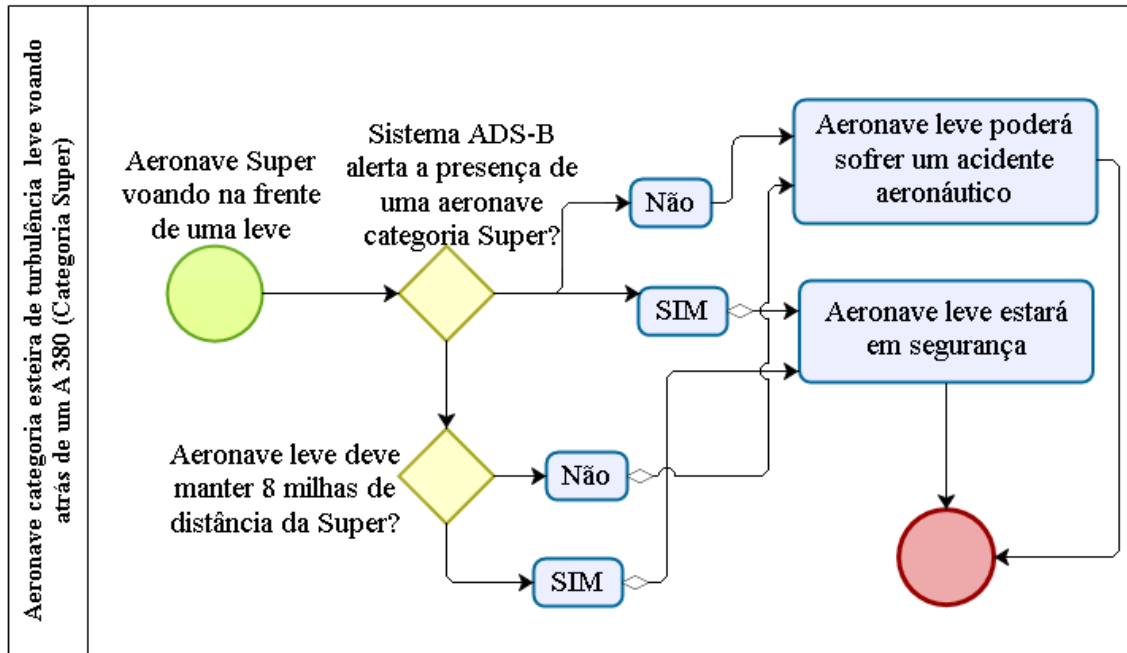


Figura 4.18: Fluxograma após implementação da solução estando a aeronave em voo usando o ADS-B e técnicas de Machine Learning.

A solução proposta é justamente que o ADS-B possa alertar o piloto da presença de categorias de esteiras de turbulência ao seu redor que possam lhe causar danos e orientá-lo a aguardar mais ou avisá-lo a manter distância. Deve se ter cuidado principalmente no momento da decolagem e do pouso onde a aeronave está próxima do solo e possivelmente o piloto não consiga retomar a aeronave devido a perda de altitude e velocidade em decorrência dos efeitos da esteira de turbulência.



Figura 4.19: Esteira de turbulência na decolagem e no pouso [25].

4.5 ADS-B Atual e ADS-B depois da Solução Proposta

Foi criada uma solução específica que alerta o piloto quando o ADS-B detecta ao seu redor uma aeronave que pode causar perigo.

4.5.1 ADS-B Atual

O ADS-B atualmente informa altitude, posição, velocidade, entre outros, mas não informa qual categoria de esteira de turbulência está ao seu redor.



Figura 4.20: Tela do ADS-B exibindo o seu tráfego [21].

4.5.2 ADS-B com a Solução Proposta

O que acontece quando o ADS-B detectar uma aeronave em voo com uma esteira de turbulência muito forte?

1. *ADS-B Visual* irá exibir em sua tela uma imagem em vermelho de uma aeronave gerando uma esteira de turbulência. A imagem irá piscar intermitentemente para chamar a atenção do piloto.

2. *ADS-B Informativo* irá exibir ao lado da imagem em vermelho que se trata, por exemplo, de uma aeronave categoria esteira de turbulência "SUPER", que se trata de um "A380" e que se encontra a 8NM de distância de sua aeronave.
3. *ADS-B Oral* irá oralmente alertar o piloto, por exemplo, que a 8NM a sua frente tem um "A380 SUPER" a 500 pés acima para que o piloto possa evitar um acidente.



Figura 4.21: Tela do ADS-B exibindo a detecção da esteira de turbulência de um Airbus A380.

O que acontece quando o ADS-B detectar uma aeronave que acabara de decolar, na qual gera uma esteira de turbulência muito forte?

1. *ADS-B Visual* irá exibir em sua tela uma imagem em vermelho de uma aeronave gerando uma esteira de turbulência ao final da pista. A imagem irá piscar intermitentemente para chamar a atenção do piloto.

2. *ADS-B Informativo* irá exibir ao lado da imagem em vermelho que se trata, por exemplo, de uma aeronave categoria esteira de turbulência "SUPER", que se trata de um "A380" e que o piloto deve aguardar 3 minutos para poder decolar com segurança.
3. *ADS-B Oral* irá oralmente alertar o piloto, por exemplo, que a sua frente tem um "A380 SUPER" e que deve aguardar 3 minutos para evitar que o piloto venha sofrer um acidente.



Figura 4.22: Tela do ADS-B exibindo a detecção da esteira de turbulência de um Airbus A380.

O que acontece quando o ADS-B detectar uma aeronave que acabara de pousar, na qual gera uma esteira de turbulência muito forte?

1. *ADS-B Visual* irá exibir em sua tela uma imagem em vermelho de uma aeronave gerando uma esteira de turbulência no centro da pista. A imagem irá piscar intermitentemente para chamar a atenção do piloto.
2. *ADS-B Informativo* irá exibir ao lado da imagem em vermelho que se trata, por exemplo, de uma aeronave categoria esteira de turbulência "SUPER", que se trata de um "A380" e que o piloto deve manter distância de 8NM para poder pousar com segurança.

3. *ADS-B Oral* irá oralmente alertar o piloto, por exemplo, que a sua frente tem um "A380 SUPER" e que deve manter distância de 8NM para evitar que o piloto venha sofrer um acidente.



Figura 4.23: Tela do ADS-B exibindo a detecção da esteira de turbulência de um Airbus A380.

Capítulo 5

Simulações e Resultados

Para o estudo de caso, foi pensado em uma aplicação no ADS-B de geração de alertas de acordo com a categoria de esteira de turbulência da aeronave. Na aplicação desenvolvida, os dados de separação e de tempo para decolagem são a fonte de dados utilizados para indicar as aeronaves ao redor que possuem um potencial perigo e com isso evitar acidentes.

Neste capítulo são apresentados os experimentos utilizados para a análise e validação da solução proposta. São definidos diferentes cenários de teste, formados a partir de decolagens, pousos e separações, compostos pela combinação de determinados parâmetros de classificação. Também são discutidos os processos utilizados para a seleção de parâmetros e a avaliação dos resultados obtidos. Em seguida, para cada componente da solução proposta e para cada cenário de teste, são apresentados os resultados dos experimentos selecionados. Por fim, os resultados obtidos são discutidos e analisados.

5.1 Configuração dos Cenários de Teste

O cenário de teste é composto por aeronaves em fase de decolagem ou de pouso e de manter a distância vertical e horizontal para com outras aeronaves. Para cada cenário de teste definido, a solução proposta é aplicada em sua *totalidade*.

5.1.1 Seleção de Algoritmos

É necessário definir alguns algoritmos para a configuração do processo para assegurar a segurança de aeronaves em relação as esteiras de turbulência de outras aeronaves. O parâmetro de *medida de distância* é compartilhado na utilização do algoritmo de classificação usando as técnicas de Aprendizado de Máquina. Os parâmetros gerais são descritos a seguir:

1. *Distância entre Aeronaves* - definida como separação mínima. A escolha dos valores de distância é de acordo com as especificações das categorias de esteiras de turbulência (leve, médio inferior, médio superior, pesado inferior, pesado superior e super pesada).
2. *Medida de Tempo para Decolagem* - Os algoritmos de classificação irão apontar o momento seguro para uma decolagem de acordo com a categoria de esteira de turbulência apontado pelo rastreamento feito no ADS-B.

Dessa forma, com a medida de distância e de tempo como parâmetros que variam dentre os vários tipos de aeronaves, para cada cenário de teste serão realizadas simulações utilizando as medidas definidas nas seções 4.2.5 e 4.2.6.

5.1.2 Seleção de Parâmetros - Algoritmos de Classificação

Para utilização dos algoritmos de Árvores de Decisão "C4.5", de *Naive Bayes*, de funções Perceptron Multiplas Camadas (MLP) e do Vizinho mais Próximo (K-Nearest Neighbors Classifier) como classificadores para ensinar o ADS-B através dos dados inseridos que a cada vez que um padrão se repita ou um padrão novo surja, que o sistema possa prever qual categoria de esteira de turbulência está ao redor da aeronave, pois o sistema já aprendeu a abordagem requerida. Os casos de testes, os parâmetros gerais, os parâmetros específicos de cada algoritmo serão definidos por meio de combinações de acordo com os cenários.

5.2 Experimentos

Para uma melhor avaliação da solução proposta, os experimentos serão avaliados sob a ótica de cada cenário apresentado. Vários cenários foram simulados usando as técnicas de Aprendizagem de Máquina e os dados da seção 4.2.5 e 4.2.6. Para melhor compreensão do agregado, os experimentos serão apresentados sob a ótica de cada *processo* da solução apresentada: Tempo para decolagem e separação em voo e no pouso. Os cenários de teste foram divididos nas subseções subsequentes.

5.2.1 Cenário 1: Tempo para Decolagem Segura

Na figura 5.1, temos o primeiro cenário de tempo de espera para uma aeronave decolar após outra aeronave ter decolado primeiro. Fazendo com que o sistema informe ao piloto que o tempo de espera já passou e que o mesmo pode executar a decolagem com segurança.

Para decolar é necessário esperar no mínimo de 2 a 3 minutos dependendo da categoria de esteira de turbulência da aeronave à frente.



Figura 5.1: Aeronave decolando e gerando sua esteira de turbulência [29].

5.2.2 Cenário 2: Distância Baseada na Separação Mínima em Voo

Na figura 5.2 e 5.3, temos o segundo cenário que apresenta a distância segura de uma aeronave para outra em voo e especialmente no momento da aproximação, ou seja, do pouso. O sistema informa ao piloto para manter uma distância segura e que o mesmo não seja atingido pela esteira de turbulência. Em voo a aeronave deve manter uma distância de no mínimo de 3 a 8 milhas dependendo da categoria de esteira de turbulência da aeronave à frente.



Figura 5.2: Esteira de turbulência de um avião em voo [47].



Figura 5.3: Aeronave pousando e gerando sua esteira de turbulência [28].

As figuras 5.1, 5.2 e 5.3 têm por objetivo ajudar: 1) na compreensão da envergadura de uma esteira de turbulência no momento da decolagem, de um pouso e de uma separação em voo; e 2) na identificação de melhorias ao processo utilizado.

5.3 Metodologia - Resultados

Para obtenção dos resultados foi feito um *dataset* contendo a distância em milhas que uma aeronave deve ter para outra em voo e no momento do pouso. Utilizado também dados de tempo em minutos para uma decolagem segura de acordo com a categoria da esteira de turbulência de cada aeronave. O *dataset* é composto das classes *YES* e *NO*, ou seja, *YES* quando a aeronave se encontrar numa situação perigosa e o *NO* quando a aeronave não corre riscos. As instâncias foram definidas de acordo com os critérios mínimos de separação e tempo das categorias das esteiras de turbulência das aeronaves (LIGHT/SUPER HEAVY, LIGHT/UPPER HEAVY, LIGHT/LOWER HEAVY, LIGHT/UPPER MEDIUM, LIGHT/LOWER MEDIUM, LIGHT/LIGHT, LOWER MEDIUM/SUPER HEAVY, LOWER MEDIUM/UPPER HEAVY, LOWER MEDIUM/LOWER HEAVY, LOWER MEDIUM/UPPER MEDIUM, LOWER MEDIUM/LOWER MEDIUM, LOWER MEDIUM/LIGHT, UPPER MEDIUM/SUPER HEAVY, UPPER MEDIUM/UPPER HEAVY, UPPER MEDIUM/LOWER HEAVY, UPPER MEDIUM/UPPER MEDIUM, UPPER MEDIUM/LOWER MEDIUM, UPPER MEDIUM/LIGHT, LOWER HEAVY/SUPER HEAVY, LOWER HEAVY/UPPER HEAVY, LOWER HEAVY/LOWER HEAVY, LOWER HEAVY/UPPER MEDIUM, LOWER HEAVY/LOWER MEDIUM, LOWER HEAVY/LIGHT, UPPER HEAVY/SUPER HEAVY, UPPER HEAVY/UPPER HEAVY, UPPER HEAVY/LOWER HEAVY, UPPER HEAVY/UPPER MEDIUM, UPPER HEAVY/LOWER MEDIUM, UPPER HEAVY/LIGHT, SUPER HEAVY/SUPER HEAVY, SUPER HEAVY/UPPER HEAVY, SUPER HEAVY/LOWER HEAVY, SUPER HEAVY/UPPER MEDIUM, SUPER HEAVY/LOWER MEDIUM, SUPER HEAVY/LIGHT).

5.4 Avaliação do Resultado dos Cenários

Os resultados foram obtidos através da ferramenta *Waikato Environment for Knowledge Analysis* (WEKA), utilizada como forma de validar, treinar e testar a base de dados criada para este projeto. Foi utilizado quatro algoritmos classificadores no *WEKA* para validação da base de dados: Rede Neural *Multilayer Perceptron* (*grupo functions*), Árvore C4.5 (J48) (*grupo trees*), método *K-Nearest Neighbors Classifier* (*grupo IBK*) e o método de *Naive Bayes* (*grupo bayes*). Foi feito o pré-processamento com o *dataset* dos dados

das categorias de esteiras de turbulência das aeronaves. Na fase de treino foi utilizada a validação cruzada com 10 dobras (*folds*) para todo o conjunto de dados.

5.4.1 Naive Bayes

Cria estimativas dos valores de precisão a partir dos dados utilizados no treinamento. Foi utilizado 36 instâncias de categorias de esteiras de turbulência, em que o Algoritmo *Naive Bayes* classificou corretamente 35 instâncias e classificou incorretamente 1 instância.

Tabela 5.1: Resultado médio das classes - Naive Bayes.

ACURÁCIA	PRECISÃO	TP	FP
97.222%	97.4%	97.2%	2.8%

A Tabela confusão 5.2, aponta que o algoritmo classificou corretamente para a classe "yes" e que errou um para a classe "no".

Tabela 5.2: Matriz Confusão - Naive Bayes.

Classificado como	a	b
a = yes	18	0
b = no	1	17

5.4.2 Perceptron Multicamadas

É uma rede neural que usa para treinamento a retropropagação de erros, ou seja, corrige os pesos. Taxa de Aprendizado informa a proporção em que a rede irá transmitir o erro, pois realizará a correção dos pesos. Taxa de aprendizado maior acelera o treino, mas a rede pode ultrapassar do ponto ótimo. Taxa menor desacelera o treino, mas aumenta a precisão da busca. Foi utilizado 36 instâncias de categorias de esteiras de turbulência, em que o Algoritmo MLP classificou corretamente 33 instâncias e classificou incorretamente 3 instâncias.

Parâmetro Taxa de Aprendizado = 0.3

Tabela 5.3: Resultado médio das classes - MLP.

ACURÁCIA	PRECISÃO	TP	FP
91.666%	91.8%	91.7%	8.3%

A Tabela confusão 5.4, aponta que o algoritmo classificou erroneamente dois para a classe "yes" e um para a classe "no".

Tabela 5.4: Matriz Confusão - MLP.

Classificado como	a	b
a = yes	16	2
b = no	1	17

5.4.3 Árvore de Decisão *C4.5*

O algoritmo C4.5 no software de mineração de dados Weka usa a implementação chamada J48. Parâmetros utilizados, fator de confiança 0,25 e o número mínimo de padrões por folha foi 10. Foi utilizado 36 instâncias de categorias de esteiras de turbulência, em que o Algoritmo J48 classificou corretamente 34 instâncias e classificou incorretamente 2 instâncias.

Tabela 5.5: Resultado médio das classes - J48.

ACURÁCIA	PRECISÃO	TP	FP
94.444%	95%	94.4%	5.6%

A Tabela confusão 5.6, aponta que o algoritmo classificou corretamente para a classe "yes" e que errou duas para a classe "no".

Tabela 5.6: Matriz Confusão - J48.

Classificado como	a	b
a = yes	18	0
b = no	2	16

5.4.4 K - Vizinhos mais Próximos

IBK é uma implementação do algoritmo KNN (*K-nearest neighbors*). Foi utilizado 36 instâncias de categorias de esteiras de turbulência, em que o Algoritmo IBK classificou corretamente 35 instâncias e classificou incorretamente 1 instância.

Parâmetro k = 1 ou 3

Tabela 5.7: Resultado médio das classes - IBK.

ACURÁCIA	PRECISÃO	TP	FP
97.222%	97.4%	97.2%	2.8%

A Tabela confusão 5.8, aponta que o algoritmo classificou corretamente para a classe "yes" e errou um para a classe "no".

Tabela 5.8: Matriz Confusão - IBK.

Classificado como	a	b
a = yes	18	0
b = no	1	17

Parâmetro $k = 5$

Tabela 5.9: Resultado médio das classes - IBK.

ACURÁCIA	PRECISÃO	TP	FP
94.444%	94.4%	94.4%	5.6%

A Tabela confusão 5.10, aponta que o algoritmo classificou erroneamente um para a classe "yes" e errou um para a classe "no".

Tabela 5.10: Matriz Confusão - IBK.

Classificado como	a	b
a = yes	17	1
b = no	1	17

Parâmetro $k = 7$ ou 9

Tabela 5.11: Resultado médio das classes - IBK.

ACURÁCIA	PRECISÃO	TP	FP
91.666%	92.9%	91.7%	8.3%

A Tabela confusão 5.12, aponta que o algoritmo classificou erroneamente três para a classe "yes" e acertou todos para a classe "no".

Tabela 5.12: Matriz Confusão - IBK.

Classificado como	a	b
a = yes	15	3
b = no	0	18

5.4.5 Análise dos Resultados dos Algoritmos

Objetivando uma sequência uniforme de experimentos (combinação de algoritmos e seus parâmetros num dado cenário de teste) que foram avaliados. Este modelo utilizado é uma das principais contribuições e descobertas deste presente trabalho. Para os cenários de teste e experimentos combinados foram obtidos resultados satisfatórios.

O classificador *IBK* com parâmetro $k = 1$ ou 3 apresentou uma acurácia de 97.222% e com uma taxa média bem baixa de falsos positivos de 2.8%. O *IBK* com parâmetro $k = 5$ apresentou uma acurácia de 94.444% e com uma taxa média bem baixa de falsos positivos de 5.6%. O *IBK* com parâmetro $k = 7$ ou 9 apresentou uma acurácia de 91.666% e com uma taxa média bem baixa de falsos positivos de 8.3%. O *Naive Bayes* teve uma acurácia de 97.222% e com uma taxa média bem baixa de falsos positivos de 2.8%. O próximo foi o *J48* com uma acurácia de 94.444% e com uma taxa média baixa de falsos positivos de 5.6%, isto é, maior que a do *IBK* e do *Naive Bayes*. Por último o *MLP* com uma acurácia de 91.666% e com uma taxa média de falsos positivos de 8.3%, ou seja, maior que a dos outros algoritmos.

Na comparação os classificadores se mostraram com resultados bem satisfatórios utilizando os dados da figura 4.4. O classificador *IBK* com parâmetro $k = 1$ ou 3 e o *Naive Bayes* apresentaram os melhores resultados, com uma acurácia de mais de 97%. Sendo que o classificador *J48* teve uma acurácia de mais de 94%, em que foi similar ao *IBK* com parâmetro $k = 5$. E com o pior resultado entre os algoritmos o *MLP* com pouco mais de 91%, em que foi similar ao *IBK* com parâmetro $k = 7$ ou 9 .

Não é à toa que o algoritmo *IBK* foi um dos que se mostrou com melhor desempenho, pois para a solução do problema proposto, em que se baseia em distâncias de aeronaves ao redor se molda perfeitamente com o que o algoritmo *IBK* se propõe, pois usa o princípio do vizinho mais próximo. O *Naive Bayes* também se mostrou bem eficiente realizando cálculos probabilísticos de um dado evento que ainda não ocorreu, sendo que outro já ocorreu.

Pelas métricas apresentadas é perfeitamente solucionável o problema de esteiras de turbulência, pois com a geração de informações por meio de alertas e culminando em orientações orais ao piloto é mais do que suficiente para evitar que a aeronave seguidora

ou a que cruzará uma aeronave maior sofra com o impacto que a esteira de turbulência provoca.

Portanto, os testes de acordo com os cenários foram para alinhar os algoritmos de Inteligência Artificial em um contexto real da aviação tripulada. Tal sistema é importante para qualquer procedimento que evite adentrar uma esteira de turbulência. A implementação atual dessa solução para o ADS-B é um passo destacável para a segurança da aviação.

5.4.6 Resultados

O sistema de vigilância aérea automático dependente por radiodifusão – ADS-B informa principalmente a altitude, posição e velocidade de outras aeronaves aos seu redor, mas não reporta qual a categoria de esteira de turbulência da aeronave.

Como resultado efetivamente alcançado com a solução desenvolvida nesse trabalho tem se um ADS-B inteligente que gera alertas visuais e orais para avisar o piloto que ao seu redor existe uma aeronave que gera uma esteira de turbulência muito forte. Os resultados são extremamente satisfatórios para a segurança em voo e principalmente para as empresas aéreas que sofrem financeiramente e com sua imagem denegrida com esses acidentes, pois muitas vidas já se perderam em sinistros aéreos e altas indenizações são pagas.

Capítulo 6

Conclusões e Trabalhos Futuros

A solução para o problema de acidentes envolvendo esteiras de turbulência vem auxiliar os pilotos com antecedência na tomada de decisões em voo ou no solo. Como consequência direta, a solução aumenta a percepção do piloto de forma automatizada por meio de técnicas de Inteligência Artificial sobre as aeronaves que estão ao seu redor e que em última análise, venha salvar vidas e evitar prejuízos financeiros aos proprietários de aeronaves.

Foi apresentada uma solução para o problema de esteiras de turbulência com os seguintes dados: separação de uma aeronave para outra em voo/pouso e o tempo em minutos para poder decolar com segurança. A solução proposta tem como objetivo usar e melhorar as funcionalidades do ADS-B para possibilitar a identificação de esteiras de turbulência e alertar o piloto para o perigo que se aproxima.

Os resultados obtidos no estudo de caso se mostraram satisfatórios, na medida em que foi possível ter um retorno do que se desejava. Dessa forma, com o desenvolvimento do trabalho, foi possível aplicar algoritmos de *classificação* de Aprendizado de Máquina na busca de soluções para o Transporte Aéreo.

Assim sendo, a melhoria de se ter na Tela de Informação de Tráfego (Cockpit Display of Traffic Information - CDTI) do ADS-B é pensada com o intuito de aprimorar as informações fornecidas e utilizando técnicas de classificação dentro da Inteligência Artificial foi possível prestar uma solução robusta que aponte o nível de perigo de uma esteira de turbulência e com isso evitar incidentes, sinistros aéreos e consequentemente mortes.

6.1 Contribuições e Pesquisas Futuras

Após a conclusão do presente trabalho, é possível listar de forma objetiva as contribuições do estudo realizado, dentre elas estão:

Apresentar uma tecnologia que permite aeronaves voarem cada vez mais próximas das esteiras de turbulência de forma segura, mas que também evite ao máximo por meio

de soluções computacionais que acidentes que já aconteceram recentemente em 2017 não venham a se repetir.

O estudo sobre o alerta aos pilotos de um iminente perigo, desencadeado pelo Laboratório de Transporte Aéreo (TransLab) do Departamento de Ciências da Computação da UnB, possibilita levantar importantes garantias de segurança para a sociedade. Com os feitos aqui explicitados, é possível dar uma compreensão a muitos usuários que não conhecem a sistemática por trás da sua segurança em uma aeronave.

Para a efetivação do trabalho, foram desenvolvidas as seguintes atividades:

1. Proposição de uma metodologia computacional para o problema de acidentes relacionados a esteiras de turbulência;
2. Levantamento do peso máximo de decolagem das aeronaves para definir qual a sua respectiva esteira de turbulência.
3. Levantamento de mínimos de separação através de dados da *Eurocontrol*;
4. Levantamento do estado da arte de algoritmos de classificação da aprendizagem supervisionada;
5. Desenvolvimento de uma solução segundo a metodologia proposta, que possui como componentes: prover alertas aos pilotos, detecção de esteiras de turbulências danosas em voo e na decolagem através da utilização de algoritmos de classificação;
6. Simulação de diversos experimentos em diferentes cenários de teste;
7. Utilização de diferentes métricas para avaliar e comparar experimentos através da análise dos resultados obtidos;
8. Identificação de modelos e parâmetros ótimos para os componentes propostos através da comparação das simulações realizadas a partir dos experimentos em diferentes cenários de teste, onde se chegou à conclusão, por exemplo, que o melhor modelo de detecção das esteiras de turbulência de aeronaves foi obtido com a utilização do algoritmo de classificação *IBK* como parâmetro para medida de distância e de tempo.

A partir das contribuições apresentadas, sugere-se para pesquisas futuras:

1. Um estudo em específico das esteiras de turbulências de helicópteros, utilizando aprendizado de máquina, pois alguns helicópteros geram fortes vórtices que já derubaram até aviões.

Esteiras de helicóptero podem ser de força significativamente maior do que de uma aeronave de asa fixa com o mesmo peso. O vórtice mais forte pode ocorrer quando

o helicóptero está a funcionar a velocidades mais baixas. Alguns helicópteros de tamanho médio ou classe executiva produzem esteiras tão fortes como a de helicópteros mais pesados. Isto é porque principais sistemas de rotor de duas pás, típicos de helicópteros mais leves, produzem um vórtice mais forte do que os sistemas de rotor com mais lâminas. A forte esteira do helicóptero *Sino Boeing V-22 Osprey tiltrotor* pode se estender além da descrição no manual, o que contribuiu para um acidente [78].

2. Realizar um estudo sobre as esteiras de turbulência em altas altitudes, pois a Agência Europeia de Segurança de Voo (EASA) aponta que, a grandes altitudes de cruzeiro, a perigosa esteira de turbulência, gerada por vórtices dos aviões pesados, podem se estender a até 25 mn, sendo mais comum a distâncias de 15 mn [37].

6.2 Considerações Finais

Por fim, pretende-se utilizar este trabalho para auxiliar a tomada de decisões dos pilotos no que se refere as esteiras de turbulências que já causaram vários acidentes fatais. Evitando prejuízos para as empresas aéreas e para os passageiros.

A solução para o problema aqui relatado é um avanço na capacidade de obtenção de informações de forma automatizada e que venha a possibilitar que aeronaves não sejam pegas de surpresa por um vórtice muito forte, como na figura 6.1, por exemplo.




Figura 6.1: Esteira de turbulência de um avião em voo[37]

Referências

- [1] ABERNETHY, MICHAEL: *Classificação e armazenamento em cluster*, maio 2010. <https://www.ibm.com/developerworks/br/opensource/library/os-weka2/index.html>, acesso em 2019-10-09. 7, 42
- [2] AEROCLUBECAMPINAS: *CATEGORIAS DE TURBULÊNCIA*, junho 2017. <http://aeroclubedecampinas.com.br/categorias-de-turbulencia/>, acesso em 2019-09-08. 2
- [3] AEROTIME: *Private Jet Flipped Upside Down and Fell 10,000ft*, março 2017. <https://www.aerotime.aero/aerotime.extra/22983-private-jet-flipped-upside-down-and-fell>, acesso em 2019-09-07. x, 3, 4
- [4] AIRCRAFTSALES: *1987 Antonov AN2*. <https://aircraftsales.us/listings/1987-an-2/#>, acesso em 2019-09-08. xii, 88
- [5] AIRPLANEPICTURES: *Robin DR400 series*. <https://www.airplane-pictures.net/type.php?p=394>, acesso em 2019-09-08. xii, 88
- [6] AKBAR, JAY: *Turbulence terror qantas passengers' terror as plane plunges into 10-second nosedive after hitting vortex turbulence from another jet*, junho 2018. <https://www.thesun.co.uk/news/6526322/qantas-flight-nosedive-vortex-la-melbourne-qf94/>, acesso em 2019-10-09. xii, 85
- [7] ANAC: *Acidentes e incidentes*, maio 2018. <https://www.anac.gov.br/en/safety/aeronautical-meteorology/conditions/turbulence>, acesso em 2019-09-07. x, 10, 86, 87, 88, 89, 90, 91, 94, 95
- [8] ANALYTICS VIDHYA CONTENT TEAM: *A Complete Tutorial on Tree Based Modeling from Scratch (in R Python)*, abril 2016. <https://www.analyticsvidhya.com/blog/2016/04/complete-tutorial-tree-based-modeling-scratch-in-python/>, acesso em 2019-09-08. 35
- [9] AOPA - Aircraft Owners and Pilots Association: *WAKE TURBULENCE RIPS AIRCRAFT APART CHI06FA154*. <https://www.aopa.org/training-and-safety/air-safety-institute/accident-analysis/featured-accidents/wake-turbulence-rips-aircraft-apart>, acesso em 2019-12-03. 1

- [10] ATR USA: *Integrated Turbulence Cockpit Displays*. http://www.atr-usa.com/sub_pages/integrated_turb.html, acesso em 2019-09-08. x, 15
- [11] BAAA: *CRASH OF A LEARJET 45 IN MEXICO CITY, MEXICO: 16 KILLED*. <https://www.baaa-acro.com/crash/crash-learjet-45-mexico-city-mexico-16-killed>, acesso em 2019-09-09. xii, 92, 93
- [12] BARBON: *Rna – perceptron multicamadas*. UEL. http://www.barbon.com.br/wp-content/uploads/2013/08/RNA_Aula51.pdf, acesso em 2019-10-09. 34
- [13] BARBOSA, IURI SOUZA RAMOS: *Abordagem de agrupamento no planejamento de voo sob tempo severo*. UnB, julho 2019. 57, 58
- [14] BARRETO, JORGE: *Introdução as redes neurais artificiais*. 2002. 2002. <http://www.inf.ufsc.br/~j.barreto/tutoriais/Survey.pdf>, acesso em 2019-10-07. 32
- [15] BBC NEWS BRASIL: *Como é a tecnologia para acompanhar e rastrear um avião?*, março 2014. <https://noticias.r7.com/internacional/como-e-a-tecnologia-para-acompanhar-e-rastrear-um-aviao-13032014>, acesso em 2019-09-08. x, 12
- [16] BECKER, LAURO: *Algoritmo de Classificação Naive Bayes*, setembro 2019. <https://www.organicadigital.com/seeds/algoritmo-de-classificacao-naive-bayes/1>, acesso em 2019-09-17. 30
- [17] BUENO, ANDRE LUIS CAVALCANTI: *Relaxamento Adaptativo da Sincronização Através do Uso de Métodos de Aprendizagem Supervisionada*. Tese de Doutorado, PUC RIO, 2018. x, 28, 29
- [18] CAREY, BILL: *Committee: ADS-B In' Not Currently Justified*, novembro 2011. <https://www.ainonline.com/aviation-news/air-transport/2011-11-21/committee-ads-b-not-currently-justified>, acesso em 2019-09-08. x, xi, 10, 43
- [19] CARVALHO, CAIO: *BOEING B747*, maio 2017. <https://www.tecmundo.com.br/aviao/116407-custa-manter-aviao-boeing-747-ar-hora.htm>, acesso em 2019-09-08. xii, 94
- [20] CENIPA: *Mca 3-6 manual de investigação do sipaer*. 2017. 45
- [21] CLAY: *Four Ways To Master Your Airplane's GPS On The Ground*, agosto 2017. <http://clayviation.com/2017/08/30/four-ways-to-master-your-airplanes-gps-on-the-ground/>, acesso em 2019-09-08. xi, 61
- [22] CONNER, KEVIN J; e ISHIHARA, YASUO; BERRY RAY: *Sistema e método para processar e exibir turbulência de ativação*. Patente US 9.037.319. 8
- [23] CUNHA, ADILSON MARQUES: *Figura 2- uploaded*, novembro 2012. https://www.researchgate.net/figure/Figura-2-Representacao-do-avionico-ADS-B-Out-e-interfaces-com-demaiss-equipamentos-fig2_267328960, acesso em 2019-09-08. x, 22

- [24] DECEA: *Serviços de Tráfego Aéreo*, dezembro 2018. <https://publicacoes.decea.gov.br/?i=publicacao&id=4993>, acesso em 2019-09-08. 3, 98
- [25] ESPINDOLA, JEFERSON ANTONIO: *Esteiras de Turbulência, O risco dos Vórtices Invisíveis*, dezembro 2009. <https://www.aviacaofederal.com.br/2009/12/esteiras-de-turbulencia-o-risco-dos.html>, acesso em 2019-09-08. xi, 60
- [26] EUROCONTROL: *European wake turbulence categorisation and separation minima on approach and departure (recat-eu)*. 2015. xi, 47, 48, 49, 50, 51, 52, 53, 54, 55, 56, 57, 105
- [27] FABRO, JOÃO ALBERTO: *If67d – sistemas inteligentes 1*. 2015. <http://www.dainf.ct.utfpr.edu.br/~fabro/IF67D/SlidesRNA/ProbBack.pdf>, acesso em 2019-09-09. x, 33
- [28] FLANKER41: *Emirates 777 Wake Vortex Landing*, agosto 2013. <https://www.military.com/video/commercial-aviation/civil-aviation/emirates-777-wake-vortex-landing/2630275674001>, acesso em 2019-09-08. xii, 68
- [29] FORMULA1: *Drag*. <http://www.formula1-dictionary.net/drag.html>, acesso em 2019-09-08. xii, 67
- [30] GARCIA, SIMONE CARBONI: *O uso de Árvores de decisão na descoberta de conhecimento na Área da saúde*. 2003. <https://www.lume.ufrgs.br/bitstream/handle/10183/4703/000503532.pdf?sequence=1>, acesso em 2019-10-01. 36
- [31] GIANCARLO, LUCCA, IGOR PEREIRA, ANDRÉ PRISCO e EDUARDO BORGES: *Uma implementação do algoritmo naïve bayes para classificação de texto*. <http://www.lbd.dcc.ufmg.br/colecoes/erbd/2013/0019.pdf>, acesso em 2019-09-23. 31
- [32] GROSSI, ANDRÉ AUGUSTO: *Comparação e avaliação de técnicas de aprendizado de máquina para indicação de biópsia para o câncer de próstata*. 2013. <http://www.uel.br/cce/dc/wp-content/uploads/TCC-AndreDelGrossi-BCC-UEL-2013.pdf>. 27, 32, 35, 43
- [33] HAWAIIAN: *The End of an Era: Aloha Boeing 767*, janeiro 2019. <https://newsroom.hawaiianairlines.com/blog/the-end-of-an-era-aloha-boeing-767>, acesso em 2019-09-09. xii, 92
- [34] IMGARIT: *AN225 vs A380*. <https://imgarit.pw/an-225-vs-a380.html>, acesso em 2019-09-07. xi, 45
- [35] JAZZAERO: *O que é o sistema ADS-B? Automatic Dependent Surveillance-Broadcast*, janeiro 2019. <https://jazzaero.com.br/aviacao-experimental/sistema-ads-b/>, acesso em 2019-09-08. x, 1, 17, 19, 20
- [36] JOSÉ, ITALO: *KNN (K-Nearest Neighbors) 1*, julho 2018. <https://medium.com/brasil-ai/knn-k-nearest-neighbors-1-e140c82e9c4e>, acesso em 2019-10-09. xi, 37, 38, 39

- [37] KLOTZEL, ERNESTO: *Agência europeia emite alerta sobre riscos de esteiras de turbulência de superjumbos*, julho 2017. <https://url.gratis/HGSSg>, acesso em 2019-09-07. xii, 77
- [38] KOTSIANTIS, SOTIRIS; KANELLOPOULOS, DIMITRIS; PINTELAS PANAGIOTIS: *Data preprocessing for supervised learning. international journal of computer science. v. 1, n. 2, p. 111–117, 2006.*). 40
- [39] LABODA, AMY: *ADS-B IN and The Traffic Question*, julho 2012. <https://www.kitplanes.com/ads-b-in-and-the-traffic-question/>, acesso em 2019-09-08. x, 22
- [40] LEDWICH, SHANNON: *Groundbreaking app helps Delta pilots avoid turbulence*, agosto 2016. <https://news.delta.com/tags/flight-weather-viewer>, acesso em 2019-09-08. x, 11, 16
- [41] LIASCH, JONAS: *XB-70 Valkyrie*, novembro 2011. <http://culturaaeronautica.blogspot.com/2011/11/xb-70-valkyrie-colisao-no-ar-sobre-o.html>, acesso em 2019-09-09. xii, 96
- [42] LUCINDO, LUCAS: *Implementação de um sistema ads-b através de técnicas de rádio definido por software*. IFSC, dezembro 2018. 20, 21
- [43] MANNING, CHRISTOPHER e HINRICH SCHUTZE: *Introduction to information retrieval. cambridge university press. 2008.* <https://www2.kbs.uni-hannover.de/fileadmin/institut/pdf/ti1/slides/08eval.pdf>, acesso em 2019-09-21. 31
- [44] MARINEZ, EDUARDO: *Suprema Corte atrai caso de lesionado en accidente en el que murió Mouriño*, setembro 2016. <http://lagazzettadf.com/noticia/2016/09/05/suprema-corte-atrae-caso-lesionado-accidente-murio-mourino/>, acesso em 2019-09-07. xii, 93
- [45] MARINHO, DANIEL: *Entenda os benefícios do ADS-B, sistema de vigilância aérea a ser utilizado em breve no País*, novembro 2015. <https://www.decea.gov.br/blog/?p=418>, acesso em 2019-09-08. 58
- [46] MELLO, IVAN BITAR FIUZA: *TURBULÊNCIA Descomplicada - Um guia para pilotos*, setembro 2016. <https://www.anac.gov.br/assuntos/setor-regulado/profissionais-da-aviacao-civil/meteorologia-aeronautica/arquivos/GUIAPARAPILOTOSTURBULENCIA.pdf>, acesso em 2019-09-08. 9, 11, 25
- [47] MIRA AVIATION: *Türbülans Nedir? Nasıl Meydana Gelir?*, agosto 2017. <https://mira-aviation.com/turbulans-nedir-nasil-meydana-gelir/>, acesso em 2019-09-08. xii, 68
- [48] MOHRI, MEHRYAR; ROSTAMIZADEH, AFSHIN; TALWALKAR AMEET: *Foundations of machine learning. [s.l.]: Mit press, 2012.* 2012. <https://pdfs.semanticscholar.org/e923/9469aba4bccf3e36d1c27894721e8dbefc44.pdf>, acesso em 2019-08-28. 29

- [49] MOREIRA, SANDRO: *Rede Neural Perceptron Multicamadas*, dezembro 2018. <https://medium.com/ensina-ai/rede-neural-perceptron-multicamadas-f9de8471f1a9>, acesso em 2019-10-09. 33
- [50] MÜLLER, HEIKO; FREYTAG, JOHANN: *Problems, methods, and challenges in comprehensive data cleansing*. http://www.dbis.informatik.hu-berlin.de/fileadmin/research/papers/techreports/2003-hub_ib_164-mueller.pdf, acesso em 2019-09-03. 40
- [51] NEW SCIENTIST: *BOEING INVENTA SISTEMA PARA DETECTAR TURBULÊNCIA INVISÍVEL*, janeiro 2011. <https://www.inovacaotecnologica.com.br/noticias/noticia.php?artigo=boeing-turbulencia-invisivel&id=010170110124#.Xejd3ZNKjIU>, acesso em 2019-09-08. 11
- [52] PAMPLONA, DANIEL ALBERTO; HERMETO, THYAGO SILVA; ALVES CLAUDIO JORGE PINTO; MULLER CARLOS: *Impactos na capacidade aérea através da recategorização da esteira de turbulência das aeronaves*. abril 2015. <https://www.revistas2.uepg.br/index.php/ret/article/view/11392/209209209358>, acesso em 2019-10-05. 9
- [53] PEREIRA, ROBERTO: *A saga do A340, o primeiro grande avião da Airbus*, janeiro 2019. https://aeromagazine.uol.com.br/artigo/saga-do-a340-o-primeiro-grande-aviao-da-airbus_4154.html, acesso em 2019-09-08. xii, 86, 87
- [54] PIFLIGHT: *Entenda o efeito solo (Ground Effect)*, dezembro 2018. <https://piflightteoriasdevoo2.blogspot.com/2018/12/entenda-o-efeito-solo-ground-effect.html>, acesso em 2019-09-07. x, 2, 3
- [55] PJPONTES: *A380 vs A320*, março 2012. <http://pjpontes.blogspot.com/2012/03/o-a380-em-sao-paulo.html>, acesso em 2019-09-07. xi, 46
- [56] PORTALMIE: *Novo equipamento poderá reduzir acidentes dentro de aeronaves causados por turbulência aérea*, maio 2017. <https://url.gratis/PD6rC>, acesso em 2019-09-08. 11
- [57] QUICKAVIATION: *Can a plane be hit by unseen air turbulence?*, novembro 2017. http://www.quick-aviation.com/index.php/News_detail_item_102.html, acesso em 2019-09-08. x, 14
- [58] RAY, SUNIL: *6 passos fáceis para aprender o algoritmo Naive Bayes (com o código em Python)*, abril 2016. <https://www.vooo.pro/insights/6-passos-faceis-para-aprender-o-algoritmo-naive-bayes-com-o-codigo-em-python/>, acesso em 2019-10-09. x, 31
- [59] REINKE, ANDREAS; KAUERTZ, SEBASTIAN: *Ground-based identification of wake turbulence encounters*, agosto 2018. US Patent App. 10/055,998. 9

- [60] RICCI, FRANCESCO; ROKACH, LIOR; SHAPIRA BRACHA: *Introduction to recommender systems handbook*. [s.l.]: Springer, 2011. 41
- [61] ROZA, FELIPPE SCHMOELLER: *Aprendizagem de máquina para apoio à tomada de decisão em vendas do varejo utilizando registros de vendas*. 2016. 29, 39, 41
- [62] SKYBRARY: *AIRBUS A300-600*, novembro 2014. <https://www.skybrary.aero/index.php/A306>, acesso em 2019-09-08. xii, 94
- [63] SKYBRARY: *BOEING 757-200*, outubro 2014. <https://www.skybrary.aero/index.php/B752>, acesso em 2019-09-09. xii, 95
- [64] SKYBRARY: *IAI 1124 Westwind*, novembro 2014. <https://www.skybrary.aero/index.php/WW24>, acesso em 2019-09-09. xii, 95
- [65] SKYBRARY: *PIPER Cherokee (PA-28-140 / 150/160/180)*, dezembro 2014. <https://www.skybrary.aero/index.php/P28A>, acesso em 2019-09-08. xii, 89
- [66] SKYBRARY: *BOEING 747-400 (internacional, winglets)*, março 2015. <https://www.skybrary.aero/index.php/B744>, acesso em 2019-09-08. xii, 91
- [67] SKYBRARY: *Sikorsky S-76*, março 2015. <https://www.skybrary.aero/index.php/S76>, acesso em 2019-09-08. xii, 89
- [68] SKYBRARY: *AIRBUS A-319*, agosto 2017. <https://www.skybrary.aero/index.php/A319>, acesso em 2019-09-08. xii, 91
- [69] SKYBRARY: *EMBRAER ERJ 170-100*, fevereiro 2018. <https://www.skybrary.aero/index.php/E170>, acesso em 2019-09-08. xii, 86, 87
- [70] SNOW, COLIN: *New Survey on ADS-B Tracking for Small Drones*, agosto 2015. <https://www.suasnews.com/2015/08/new-survey-on-ads-b-tracking-for-small-drones/>, acesso em 2019-09-08. x, 18
- [71] SPARTASCIENCE: *Decision Trees: Athlete Care in Big Data*, agosto 2016. <https://www.spartascience.com/resources/decision-trees-athlete-care-in-big-data>, acesso em 2019-09-08. x, xi, 35, 36
- [72] STACKEXCHANGE: *Are there useful applications for Bayes Nets (vs. Naive Bayes)?* <https://stats.stackexchange.com/questions/402859/are-there-useful-applications-for-bayes-nets-vs-naive-bayes?noredirect=1>, acesso em 2019-09-08. x, 30
- [73] STOVER, CHRISTOPHER; WEISSTEIN, ERIC: *Cartesian coordinates*. <http://mathworld.wolfram.com/CartesianCoordinates.html>, acesso em 2019-06-07. 39
- [74] USAF: *Último AC-130U Spooky retorna de missão de combate*, julho 2019. <https://www.aereo.jor.br/2019/07/23/ultimo-ac-130u-spooky-retorna-de-missao-de-combate/>, acesso em 2019-09-09. xii, 90

- [75] WALLPAPERCAVE: *A380 vs Boeing 737-330*. <https://wallpapercave.com/w/Zz7kpFF>, acesso em 2019-09-07. xi, 46
- [76] WEISSTEIN, ERIC: *Distance*. <http://mathworld.wolfram.com/Distance.html>, acesso em 2019-06-07. 39
- [77] WEISSTEIN, ERIC: *Spherical coordinates*. <http://mathworld.wolfram.com/SphericalCoordinates.html>, acesso em 2019-06-07. 40
- [78] WIKI: *Esteira de turbulência - Wake turbulence*. https://pt.qwertyu.wiki/wiki/Wake_turbulence, acesso em 2019-12-03. 1, 3, 77
- [79] WIKI: *Ângulo de ataque - angle of attack*. https://pt.qwertyu.wiki/wiki/Angle_of_attack, acesso em 2019-10-09. xi, 47
- [80] WIKIPEDIA: *F-104 Starfighter*. https://en.wikipedia.org/wiki/Lockheed_F-104_Starfighter, acesso em 2019-09-09. xii, 96
- [81] WIKIWAND: *Esteira de Turbulência*. https://www.wikiwand.com/pt/Esteira_de_turbulência, acesso em 2019-09-09. 90
- [82] WIKIWAND: *Pilatus PC-12*. https://www.wikiwand.com/pt/Pilatus_PC-12, acesso em 2019-09-09. xii, 90
- [83] WIKIWAND: *XB-70 colisão em pleno voo*. https://www.wikiwand.com/pt/Esteira_de_turbulência, acesso em 2019-09-09. xii, 97
- [84] WITTEN, IAN, EIBE FRANK e MARK HALL: *Data mining:: Practical machine learning tools and techniques (the morgan kaufmann series in data management systems). 3rd edition*. 43
- [85] WMO: *COMET AMDAR Module Produced for WMO*, março 2015. <https://public.wmo.int/en/resources/meteoworld/comet-amdar-module-produced-wmo>, acesso em 2019-09-08. x, 13

Apêndice A

Acidentes Aeronáuticos Envolvendo Esteiras de Turbulência

- Qantas QF94 em rota de Los Angeles para Melbourne, 2018.

Entende-se que o avião A380 foi atingido por uma esteira de turbulência de outro A380, que decolou apenas dois minutos antes. Os passageiros descreveram o momento em que um vórtice enviou seu voo da Qantas para um mergulho de 10 segundos sobre o Oceano Pacífico. Uma porta-voz da Qantas disse que os dois A380 estavam a uma distância segura: 20 milhas náuticas e 1000 pés de altitude.

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO A380-800: SUPER




Figura A.1: Ilustração da esteira de turbulência do voo da Qantas[6].

- Um C-130J-30, da Força Aérea Indiana, se acidentou perto de Gwalior, Índia, morreram todas as 5 pessoas a bordo, 2014. [7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO C-130: MÉDIA

Ambas as aeronaves eram LOCKHEED C130 e desceram a 300 pés de altitude para uma queda simulada. Achados preliminares sugerem que o KC-3803 atingiu a turbulência da esteira do avião que estava subindo a 1000 pés após a queda simulada. O avião provavelmente parou depois de ter atingido a turbulência, com a tripulação incapaz de se recuperar a baixa altitude.



Figura A.2: C130 KC-3803[69].



Figura A.3: Destroços do C130 KC-3803[53].

- E170, en-route, Ishioka Japan, 2014.[7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO AIRBUS A340: MÉDIA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO EMBRAER E170: MÉDIA

O E170 estava em voo quando iniciou uma descida e acabou sendo pego pela esteira de turbulência de um A340. Dois membros da tripulação sofreram lesões durante as fortes quedas de altitude, uma lesão grave e outra lesão leve.



Figura A.4: Exemplo de um Embraer E170[69].



Figura A.5: Exemplo de um Airbus A340[53].

- Robin DR 400. Três morreram e um ficou gravemente ferido, 2012. [7]

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO ANTONOV AN2: LEVE

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO ROBIN DR 400: LEVE

O Robin DR 400 realizava decolagem quando foi pego pela esteira de turbulência do Antonov AN2 que partiu pouco antes. O DR 400 atingiu o chão e explodiu em chamas.



Figura A.6: Exemplo de um Robin DR 400[5].



Figura A.7: Exemplo de um Antonov AN2[4].

- P28A / S76, Humberside UK 2009.[7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO PIPER P28A: LEVE

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO SIKORSKY S-76: LEVE

O avião Piper P28A prestes a realizar pouso se acidenta ao ser pego pela esteira de turbulência do helicóptero Sikorsky S-76.



Figura A.8: Exemplo de um PIPER Cherokee (PA-28-140)[65].



Figura A.9: Exemplo de um Sikorsky S-76 [67].

- P12 / AC130U, Campo de Hurlburt, 2008.[7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO AC130U: PESADA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO PC12: LEVE

O piloto do PC12 tentou pousar muito próximo de um AC-130U Spooky e foi pego pela esteira de turbulência desta aeronave. As regras da Força Aérea estipulam um mínimo de dois minutos de separação entre aeronaves pesadas, mas o PC-12 entrou na traseira do AC-130U com apenas 40 segundos de separação. Conforme o PC-12 atingia a esteira de turbulência, ele rolou repentinamente para a esquerda e ficou de ponta cabeça. O piloto instrutor interveio e conseguiu controlar a rolagem, mas antes que conseguisse colocar a aeronave para cima novamente a asa esquerda atingiu o solo, levando a aeronave a derrapar por 699 metros pelo campo antes de parar em um piso pavimentado[81].



Figura A.10: Exemplo de um AC-130U Spooky [74].



Figura A.11: Exemplo de um Pilatus PC-12 [82].

- A319 / B744, en-route near Oroville WA USA, 2008.[7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO BOEING 744-400: PESADA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO AIRBUS A319-100: MÉDIA

O Airbus A319-100 realizando uma subida em voo acabou adentrando a esteira de turbulência do Boeing 744. Foi submetido a solavancos repentinos e, em seguida, uma série de jogadas que resultaram em uma descida involuntária de 1.400 pés antes que o voo reto e nivelado fosse recuperado. Três dos 88 ocupantes sofreram ferimentos graves e oito sofreram ferimentos leves como resultado de quedas e colisões com móveis de aeronaves.



Figura A.12: Exemplo de um Airbus A319 [68].



Figura A.13: Exemplo de um Boeing 744 [66].

- *LearJet* 45/B767-300, Cidade do Novo México, 2008.

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO LEARJET 45: MÉDIA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO BOEING 767-300: PESADA

Outro acidente fatal em 2008 causado por esteira de turbulência se trata do *LearJet* 45, de matrícula XC-VMC. A aeronave voava atrás de um Boeing 767-300 e acima de um helicóptero pesado. Os pilotos do *Learjet* não foram avisados do tipo de aeronave em que se aproximavam, nem orientados a manter a separação segura. (Isso foi confirmado pelo Governo Mexicano através do Luiz Tellez, então Ministro de Comunicações do México).

O *Learjet* de categoria de esteira de turbulência média se aproximou demais e entrou na esteira de turbulência categoria pesada do Boeing 767-300 perdendo seu controle em uma descida descontrolada e caindo sobre vários carros, ferindo 40 pessoas em uma avenida muito movimentada próximo ao aeroporto Internacional da Cidade do México antes mesmo de iniciar o pouso. As nove pessoas no avião morreram e outras sete vítimas fatais que passavam na avenida no momento da queda.[11].



Figura A.14: Exemplo de um BOEING 767-300 [33].



Figura A.15: LearJet45, XC-VMC [11].



Figura A.16: Destroços da queda do Learjet 45-XC [44].

A separação entre o 767 e o *Learjet* deveria ser de 5 NM, os dois estavam apenas 4,15 NM. Fica evidente a importância de aprimoramentos de técnicas de Inteligência Artificial para prover alertas ao piloto de forma automática e com isso evitar acidentes e mortes.

- A306, vicinity JFK New York USA, 2001. [7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO BOEING 747: PESADA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO AIRBUS A300-600: PESADA

O Airbus A300-600 perdeu o controle apenas um minuto e meio após a decolagem, pois tivera sido atingido pela esteira de turbulência de um Boeing 747 e a subsequente destruição da aeronave por forças do impacto no solo e de um incêndio o que ocasionou a morte de todos os 260 ocupantes e cinco outros no solo. O A300 decolou cerca de 1 minuto e 40 segundos após o 747.



Figura A.17: Exemplo de um Boeing 747 [19].



Figura A.18: Exemplo de um Airbus A300-600 [62].

- WW24, vicinity John Wayne Airport Santa Ana CA USA, 1996.[7].

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO BOEING 757-200: PESADA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO IAI 1124 WESTWIND: MÉDIA

O IAI Westwind não deixou separação suficiente entre sua aeronave e o Boeing 757 à frente no momento do pouso e perdeu o controle. A aeronave caiu matando todos os ocupantes e destruindo a aeronave no impacto.



Figura A.19: Exemplo de um Boeing 757 [63].



Figura A.20: Exemplo de um IAI 1124 Westwind [64].

- XB-70/F-104, Base Aérea de Edwards, 1966.

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO XB-70: PESADA

CATEGORIA DA ESTEIRA DE TURBULÊNCIA DO F-104: MÉDIA

O F-104 foi atingido pela esteira de turbulência do XB-70 e acabou colidindo com a asa do outro avião.



Figura A.21: Exemplo de um North American XB-70 Valkyrie [41].



Figura A.22: Exemplo de um Lockheed F-104 Starfighter [80].



Figura A.23: Colisão do F-104 com o XB-70 [83].

Anexo I

Definições de Termos Aeronáuticos

As seguintes definições são utilizadas na aviação visando clarificar certos termos especializados [24]:

ACIDENTE AERONÁUTICO

Toda ocorrência aeronáutica relacionada à operação de uma aeronave, no caso de uma aeronave tripulada, havida entre o momento em que uma pessoa nela embarca com a intenção de realizar um voo até o momento em que todas as pessoas tenham dela desembarcado ou, no caso de uma aeronave não tripulada, toda ocorrência havida entre o momento que a aeronave está pronta para se movimentar, com a intenção de voo, até a sua inércia total pelo término do voo, e seu sistema de propulsão tenha sido desligado e, durante os quais, pelo menos uma das situações abaixo ocorra:

- a) uma pessoa sofra lesão grave ou venha a falecer como resultado de:
 - estar na aeronave;
 - ter contato direto com qualquer parte da aeronave, incluindo aquelas que dela tenham se desprendido; ou
 - ser submetida à exposição direta do sopro de hélice, ao rotor ou escapamento de jato, ou às suas consequências.

NOTA 1: Exceção será feita quando as lesões, ou óbito, resultarem de causas naturais, forem autoinfligidas ou infligidas por terceiros, ou forem causadas a pessoas que embarcaram clandestinamente e se acomodaram em área que não as destinadas aos passageiros e tripulantes.

NOTA 2: As lesões decorrentes de um Acidente Aeronáutico que resultem em óbito até 30 dias após a data da ocorrência são consideradas lesões fatais.

- b) a aeronave sofra dano ou falha estrutural que:
 - afete adversamente a resistência estrutural, o seu desempenho ou as suas características de voo; e

- normalmente exija a realização de grande reparo ou a substituição do componente afetado.

NOTA: Exceção será feita para falha ou danos limitados a um motor, suas carenagens ou acessórios; ou para danos limitados às hélices, às pontas de asa, às antenas, aos probes, aos pneus, aos freios, às rodas, às carenagens do trem, aos painéis, às portas do trem de pouso, aos para-brisas, aos amassamentos leves e pequenas perfurações no revestimento da aeronave, ou danos menores às pás do rotor principal e de cauda, ao trem de pouso e àqueles resultantes de colisão com granizo ou fauna (incluindo perfurações no radome).

c) a aeronave seja considerada desaparecida ou esteja em local inacessível.

NOTA 1: Uma aeronave será considerada desaparecida quando as buscas oficiais forem suspensas e os destroços não forem encontrados.

NOTA 2: Em voos de ensaio experimental de empresa certificada, não serão classificadas como acidente aeronáutico as ocorrências relacionadas diretamente ao objetivo do ensaio, ficando o estabelecimento desta relação a cargo do CENIPA, após análise preliminar do evento e da documentação técnica que suporte o referido ensaio.

ACURACIDADE

Grau de conformidade entre o valor estimado ou medido e o valor verdadeiro.

NOTA: Para os dados de posição medidos, a acuracidade é normalmente expressa em termos de uma distância a partir da posição indicada dentro da qual existe uma confiança definida da posição verdadeira.

AERÓDROMO DE ALTERNATIVA

Aeródromo para o qual uma aeronave poderá prosseguir, quando for impossível ou desaconselhável dirigir-se ou efetuar o pouso no aeródromo de destino previsto, e onde os serviços necessários e facilidades estarão disponíveis e os requisitos de performance da aeronave poderão ser atendidos, bem como estará operacional no momento pretendido de uso. São os seguintes os aeródromos de alternativa:

a) aeródromo de alternativa pós-decolagem Aeródromo de alternativa no qual uma aeronave poderá pousar, se isso for necessário, logo após a decolagem, se não for possível utilizar o aeródromo de partida.

b) aeródromo de alternativa em rota Aeródromo de alternativa no qual uma aeronave poderá pousar, caso um desvio seja necessário, enquanto estiver em rota; e

c) aeródromo de alternativa de destino Aeródromo de alternativa no qual uma aeronave poderá pousar se for impossível ou desaconselhável efetuar pouso no aeródromo de destino previsto.

NOTA: O aeródromo de partida poderá também ser designado como o aeródromo de alternativa em rota ou como o aeródromo de alternativa de destino para aquele voo.

AERONAVE

Qualquer aparelho que possa sustentar-se na atmosfera a partir de reações do ar que não sejam as reações do ar contra a superfície da terra.

AERONAVE EM EMERGÊNCIA

Toda aeronave que se encontra em situação de perigo latente ou iminente.

AERONAVE EXTRAVIADA

Toda aeronave que se desviou consideravelmente da rota prevista, ou que tenha notificado que desconhece sua posição.

AERONAVE NÃO IDENTIFICADA

Toda aeronave que tenha sido observada, ou com respeito à qual se tenha notificado que está voando em uma determinada área, mas cuja identificação não tenha sido estabelecida.

AERONOTIFICAÇÃO

Reporte de uma aeronave em voo preparado de acordo com os requisitos de informação de posição, operacional e/ou meteorológica.

AEROPLANO (AVIÃO)

Aeronave mais pesada que o ar, propulsada mecanicamente, que deve sua sustentação em voo principalmente às reações aerodinâmicas exercidas sobre superfícies que permanecem fixas em determinadas condições de voo.

AEROPORTO

Aeródromo público dotado de instalações e facilidades para apoio de operações de aeronaves e de embarque e desembarque de pessoas e cargas.

AEROVIA

Área de Controle, ou parte dela, disposta em forma de corredor.

ALTITUDE

Distância vertical entre um nível, um ponto ou objeto considerado como ponto e o nível médio do mar.

ALTURA

Distância vertical de um nível, ponto ou objeto considerado como ponto, medido a partir de um datum especificado.

APRESENTAÇÃO RADAR

Apresentação eletrônica de informações oriundas de um radar e que representa a posição e o movimento das aeronaves.

AVISO PARA EVITAR TRÁFEGO

Aviso prestado por um órgão ATS, sugerindo manobras para auxiliar um piloto, de forma a evitar uma colisão.

CENTRO DE CONTROLE DE ÁREA

Órgão estabelecido para prestar serviço de controle de tráfego aéreo aos voos controlados nas áreas de controle sob sua jurisdição.

COMUNICAÇÃO POR ENLACE DE DADOS CONTROLADOR-PILOTO

Meio de comunicação entre controlador e piloto por enlace de dados para comunicações ATC.

COMUNICAÇÃO POR ENLACE DE DADOS

Forma de comunicação destinada ao intercâmbio de mensagens por enlace de dados.

DESEMPENHO HUMANO

Capacidades e limitações humanas que repercutem na segurança e eficiência das operações aeronáuticas.

IDENTIFICAÇÃO

Situação existente quando a posição radar de uma determinada aeronave é vista na tela de vigilância e positivamente identificada.

INCIDENTE AERONÁUTICO

Toda ocorrência associada à operação de uma aeronave, havendo intenção de voo, que não chegue a se caracterizar como um acidente aeronáutico ou uma ocorrência de solo, mas que afete ou que possa afetar a segurança da operação.

INCIDENTE AERONÁUTICO GRAVE

Incidente aeronáutico envolvendo circunstâncias que indiquem que houve elevado potencial de risco de acidente relacionado à operação da aeronave, no caso de aeronave tripulada, havida entre o momento em que uma pessoa nela embarca com a intenção de realizar um voo, até o momento em que todas as pessoas tenham dela desembarcado.

NOTA 1: No caso de uma aeronave não tripulada, toda ocorrência havida entre o momento em que a aeronave está pronta para se movimentar, com a intenção de voo, até a sua inércia total pelo término do voo, e seu sistema de propulsão tenha sido desligado.

NOTA 2: A diferença entre o incidente grave e o acidente está apenas nas consequências.

NOTA 3: O Anexo C do Anexo 13 à Convenção sobre Aviação Civil Internacional apresenta uma lista de situações que podem ser consideradas exemplos de incidentes aeronáuticos graves. Essa lista serve apenas como um guia, porém não esgota os exemplos de ocorrências aeronáuticas que se enquadram na classificação de incidente aeronáutico grave.

INDICAÇÃO DE POSIÇÃO

Indicação visual, em forma simbólica ou não simbólica, sobre a situação que mostra a posição de uma aeronave, veículo de aeródromo ou outro objeto.

MANOBRA EVASIVA (BREAKOUT)

Manobra comandada por um ATCO para uma aeronave em aproximação no caso de violação da NTZ por aeronave na aproximação adjacente. A manobra evasiva poderá ser composta de manobra vertical e lateral.

NENHUM RISCO Condição na qual a segurança da operação não tenha sido comprometida.

NÍVEL

Termo genérico referente à posição vertical de uma aeronave em voo, que significa, indistintamente, altura, altitude ou nível de voo.

NÍVEL DE CRUZEIRO

Nível que se mantém durante uma etapa considerável do voo.

NÍVEL DE TRANSIÇÃO

Nível de voo mais baixo disponível para uso, acima da altitude de transição.

NÍVEL DE VOO

Superfície de pressão atmosférica constante, relacionada com uma determinada referência de pressão, 1013.2 hectopascals, e que está separada de outras superfícies análogas por determinados intervalos de pressão.

NOTA 1: O altímetro de pressão, calibrado de acordo com a atmosfera padrão, indicará:

- a) altitude - quando ajustado para "ajuste de altímetro"(QNH);
- b) altura - quando ajustado para "ajuste a zero"(QFE); e
- c) nível de voo - quando ajustado para a pressão de 1013.2 hectopascals (QNE).

NOTA 2: Os termos "altura" e "altitude", usados na NOTA 1, referem-se a alturas e altitudes altimétricas em vez de geométricas.

OCORRÊNCIA AERONÁUTICA

Qualquer evento envolvendo aeronave que poderá ser classificado como acidente aeronáutico, incidente aeronáutico grave ou incidente aeronáutico, permitindo ao SIPAER a adoção dos procedimentos pertinentes.

ROTA

Projeção sobre a superfície terrestre da trajetória de uma aeronave cuja direção, em qualquer ponto, é expressa geralmente em graus a partir do Norte (verdadeiro ou magnético).

SEPARAÇÃO

Distância que separa aeronaves, níveis ou rotas.

SEPARAÇÃO CONVENCIONAL

Separação utilizada, quando estiver sendo provido o controle convencional.

SEPARAÇÃO RADAR

Separação utilizada, quando a informação de posição da aeronave é obtida de fonte radar.

SERVIÇO DE ALERTA

Serviço prestado para notificar os órgãos apropriados a respeito das aeronaves que necessitem de ajuda de busca e salvamento e para auxiliar tais órgãos no que for necessário.

SÍMBOLO DE POSIÇÃO

Indicação visual na tela de vigilância, em forma simbólica, que mostra a posição de aeronave, veículo no aeródromo ou outro objeto, obtida após o processamento automático de dados de posição, derivados de qualquer fonte.

TELA DE VIGILÂNCIA

Uma tela eletrônica que mostra a posição e o movimento de aeronave e outras informações como requerido.

TRÁFEGO AÉREO

Todas as aeronaves em voo ou operando na área de manobras de um aeródromo.

Anexo II

Comparação dos mínimos de separação entre a ICAO e a RECAT-EU

- Diferença nos mínimos de separação de esteiras de turbulências entre a ICAO e a RECAT-EU.

Follower Leader		<i>"SUPER HEAVY"</i>	<i>"UPPER HEAVY"</i>	<i>"LOWER HEAVY"</i>	<i>"UPPER MEDIUM"</i>	<i>"LOWER MEDIUM"</i>	<i>"LIGHT"</i>
		"A"	"B"	"C"	"D"	"E"	"F"
<i>"SUPER HEAVY"</i>	"A"	(+0.5 NM)	-2 NM	-1 NM	-2 NM	-1 NM	
<i>"UPPER HEAVY"</i>	"B"		-1 NM		-1 NM		+1NM
<i>"LOWER HEAVY"</i>	"C"		-1 (-1.5) NM	-1 NM	-2 NM	-1 NM	
<i>"UPPER MEDIUM"</i>	"D"						
<i>"LOWER MEDIUM"</i>	"E"						-1 NM
<i>"LIGHT"</i>	"F"						(+ 0.5 NM)

- Diferença nos mínimos de separação de tempo das esteiras de turbulências na decolagem entre a ICAO e a RECAT-EU[26].

Leader Follower		"SUPER HEAVY"	"UPPER HEAVY"	"LOWER HEAVY"	"UPPER MEDIUM"	"LOWER MEDIUM"	"LIGHT"
		"A"	"B"	"C"	"D"	"E"	"F"
"SUPER HEAVY"	"A"		-20s		-40s	-20s	
"UPPER HEAVY"	"B"				-20s		+20s
"LOWER HEAVY"	"C"				-40s	-20s	
"UPPER MEDIUM"	"D"						
"LOWER MEDIUM"	"E"						-20s
"LIGHT"	"F"						+20s